

**UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
ESCOLA DE ENGENHARIA
PROGRAMA DE PÓS-GRADUAÇÃO MESTRADO PROFISSIONAL EM
ENGENHARIA DE PRODUÇÃO**

OTÁVIO LEMOS DE MELO CELIDONIO

**DETERMINANTES DA RECENTE EXPANSÃO DA CULTURA DA SOJA NO
ESTADO DE MATO GROSSO**

PORTO ALEGRE

2016

OTÁVIO LEMOS DE MELO CELIDONIO

**DETERMINANTES DA RECENTE EXPANSÃO DA CULTURA DA SOJA NO
ESTADO DE MATO GROSSO**

Dissertação submetida ao Programa de Pós-Graduação Mestrado Profissional em Engenharia de Produção da Universidade Federal do Rio Grande do Sul como requisito parcial à obtenção do título de Mestre em Engenharia de Produção, modalidade Profissional, na área de concentração em Sistemas de Produção de Qualidade.

Orientador: Professora Dra. Liane Werner

PORTO ALEGRE

2016

Otávio Lemos de Melo Celidonio

**Determinantes da recente expansão da cultura da soja no Estado de Mato
Grosso entre 2008 e 2013**

Esta dissertação foi julgada adequada para a obtenção do título de Mestre em Engenharia de Produção na modalidade Profissional e aprovada em sua forma final pelo Orientador e pela Banca Examinadora designada pelo Programa de Pós-Graduação em Engenharia de Produção da Universidade Federal do Rio Grande do Sul.

Prof. Orientador, Dra. Liane Werner
Orientador PMPEP/UFRGS

Prof. Ricardo Augusto Cassel
Coordenador PMPEP/UFRGS

Banca Examinadora:

Professor Ricardo Augusto Cassel, PhD (UFRGS)

Professor Michel José Anzanello, PhD (UFRGS)

Professora Denise Cybis Fontana, PhD (UFRGS)

À Raquel, esposa, companheira e mãe
dos meus filhos, que mesmo nos
momentos de incerteza sempre esteve ao
meu lado me ajudando a tomar o rumo
certo.

AGRADECIMENTOS

A construção desta dissertação foi sem dúvida o maior desafio acadêmico que vivi e uma página de agradecimentos não representa o sentimento de gratidão pelas pessoas que me apoiaram ao longo deste processo.

Primeiramente gostaria de agradecer às pessoas que me apoiaram diretamente na construção do trabalho. À professora Liane Werner, pela orientação metodológica e paciência ao conduzir a mais de dois mil quilômetros de distância. À Juliana Gil, minha colega de faculdade e pesquisadora da universidade de Wachenigen, da Holanda, que mesmo vindo na reta final do trabalho contribuiu decisivamente ao apontar os *insights* poderosos sobre a abordagem e questionamentos frequentes dos pesquisadores da área de estudo de mudanças do uso dos solos. Aos professores do departamento de Estatística da UFMT Anderson Oliveira, Marcelino Pascoa, Juliano Bortoli, Gilmar Junior e Arturo Zavala, que não se furtaram em discutir e sugerir soluções para as modelagens desenvolvidas neste trabalho.

Em segundo, agradeço especialmente ao Instituto Mato-Grossense de Economia Agropecuária (Imea) - local onde tive a honra de trabalhar e dirigir - em nome do presidente, Rui Prado, pelo apoio financeiro e institucional para a realização das disciplinas, e aos colegas Daniel Ferreira, Tiago Assis, Rondiny Moreira, Ângelo Ozelame e Paulo Ozaki, pelo apoio técnico e intelectual deste projeto.

Agradeço ao IBG e à UFRGS a oportunidade de realizar em Mato Grosso uma pós-graduação de alto nível, contribuindo de maneira relevante para a transferência de tecnologia e formação de capital humano na nossa região e ao mesmo tempo nos dar a chance de desenvolver amizades, em especial com os colegas Johnnattan, Leandro e Elisa, que ajudaram a manter viva a energia para concluir este trabalho.

Por fim, agradeço à minha esposa e companheira Raquel, que, apesar do investimento econômico e dos incontáveis finais de semana assistindo às aulas ou escrevendo este trabalho, sempre me estimulou a continuar e que, mesmo nas horas mais difíceis e em meio ao nascimento do nosso primeiro filho (Victor), a minha mudança de emprego e gestação do segundo filho (Guilherme), me deu todo o suporte, provando com atitude a força do amor e respeito do nosso relacionamento.

RESUMO

Compreender o que impulsiona, catalisa ou impede a mudança de uso da terra na fronteira agrícola brasileira é uma condição para o desenho efetivo de políticas locais, o que por sua vez pode ter implicações para a produção de alimentos, a conservação ambiental e as emissões de gases de efeito estufa em todo o mundo. Analisou-se o processo de expansão agrícola em Mato Grosso, o maior produtor agrícola do País, mapeando e quantificando a incorporação de novas áreas de cultivo e a conversão das existentes em campos mecanizados de soja no nível de fazenda. Através de modelagem estatística, também se investigou a influência de variáveis econômicas, agrônomicas e logísticas fundamentais nesse processo, considerando as recentes mudanças na legislação ambiental brasileira. Constatou-se que a área convertida para a produção de soja aumentou quase 1,5 milhão de hectares entre 2009 e 2013, porém mais de 70% ocorreram em fazendas que já possuíam soja em anos anteriores. Comparando o poder explicativo de oito modelos de regressão envolvendo diferentes grupos de variáveis, verificou-se que a expansão da soja está fortemente associada à própria presença de soja, bem como de armazéns dentro da distância de 50 a 100 quilômetros. De acordo com o modelo com os melhores resultados, a ampliação da soja também tem probabilidade de ocorrer em áreas de alto valor de conservação natural. Finalmente, a sensibilidade da expansão da soja aos preços correntes do período indicou que ainda há um grande potencial de crescimento agrícola em Mato Grosso, aumentando a importância estratégica de investimentos logísticos inteligentes que promovam o desenvolvimento regional aliado à proteção ambiental.

Palavras-chave: Mudança do uso dos solos; Expansão da agricultura; Soja; Agricultura.

ABSTRACT

Understanding what drives, catalyzes or constraints land use change in the Brazilian agricultural frontier is a condition for effective policy design at the local level, which in turn might have implications for food production, environmental conservation and GHG emissions worldwide. We analyzed the process of agricultural expansion in the state of Mato Grosso, the country's largest agricultural producer, by mapping and quantifying the incorporation of new farming areas and the conversion of existing ones into mechanized soybean fields at the farm-level. Through statistical modeling, we also investigated the influence of key economic, biophysical, environmental and logistics variables on this process while accounting for recent changes in the Brazilian environmental legislation. We found that the area converted to soybean production increased almost 1,5 million hectares between 2009 and 2013, but more than 70% of which in farms that already had some soybean in previous years. By comparing the explanatory power of eight regression models involving different groups of variables, we found that soy expansion is strongly associated with the presence of soybean fields and warehouses within a distance between 50 and 100 kilometers. According to the model with the largest explanatory results, soy expansion is likely to occur also in areas of high conservation value. Finally, the sensitivity of soy expansion to soy prices indicated the potential for further agricultural growth in Mato Grosso while highlighting how crucial smart logistics investments that promote regional development combined with environmental protection.

Keywords: Land use change; agricultural expansion; soybean; agriculture;

SUMÁRIO

| | |
|---|-----------|
| 1. INTRODUÇÃO | 11 |
| 1.1. CONSIDERAÇÕES INICIAIS..... | 11 |
| 1.2. TEMA, OBJETIVOS E JUSTIFICATIVA | 13 |
| 1.3. METODOLOGIA..... | 15 |
| 1.4. LIMITAÇÕES | 16 |
| 1.5. ESTRUTURA DO TRABALHO..... | 17 |
| 2. ESTUDOS SOBRE O USO E OCUPAÇÃO DOS SOLOS | 18 |
| 2.1. A MUDANÇA DO USO E OCUPAÇÃO DOS SOLOS NA LITERATURA..... | 18 |
| 2.2. CARACTERÍSTICAS DAS BASES DE MAPEAMENTO DO USO DOS SOLOS | 21 |
| 2.3. LEVANTAMENTO DO USO E OCUPAÇÃO DOS SOLOS..... | 22 |
| 2.4. DEFINIÇÃO E SELEÇÃO DAS VARIÁVEIS | 25 |
| 2.5. MODELAGEM DA MUDANÇA DO USO E OCUPAÇÃO DOS SOLOS..... | 27 |
| 3. PROCEDIMENTOS METODOLÓGICOS | 29 |
| 3.1. DEFINIÇÃO DAS BASES DO PROCESSO DE MAPEAMENTO..... | 29 |
| 3.2. CRITÉRIOS PARA A IDENTIFICAÇÃO DA MUDANÇA DO USO E OCUPAÇÃO DOS SOLOS..... | 31 |
| 3.3. DEFINIÇÃO DAS VARIÁVEIS DE ANÁLISE | 32 |
| 3.4. MODELAGEM DA MUDANÇA DO USO E OCUPAÇÃO DOS SOLOS..... | 36 |
| 3.5. ANÁLISE ESTATÍSTICA DOS MODELOS..... | 37 |
| 4. ESTUDO DE CASO | 39 |
| 4.1. RESULTADOS DO PROCESSO DE MAPEAMENTO DO USO E OCUPAÇÃO DOS SOLOS | 39 |
| 4.2. EVOLUÇÃO DO USO E OCUPAÇÃO DOS SOLOS DE MATO GROSSO | 41 |
| 4.3. ANÁLISE DAS VARIÁVEIS | 44 |
| 4.4. MODELAGEM DA MUDANÇA DO USO E OCUPAÇÃO DOS SOLOS..... | 51 |
| 4.5. ANÁLISE ESTATÍSTICA DOS MODELOS..... | 55 |
| 5. DISCUSSÕES | 66 |
| 6. CONSIDERAÇÕES FINAIS | 69 |
| REFERÊNCIAS | 71 |

LISTA DE ILUSTRAÇÕES

| | |
|---|----|
| Figura 1 - Resultado do projeto Siga-MT (Imea e Sinoptica, 2014) apresentando o visualizador n-D agrupando as amostras de campo mais representativas de cada cultura, com as bandas temporais MODIS 2 (28/08/2012), 7 (16/11/2012) e 12 (02/02/2013) | 24 |
| Figura 2 - Resultado do projeto Siga-MT (Imea e Sinoptica, 2014) apresentando o quadro da matriz de confusão do cruzamento entre os dados reais de uso e ocupação levantadas a campo e o uso e ocupação dados pelo procedimento de classificação do projeto. | 25 |
| Figura 3 - Grid de unidades fundiárias mínimas e recorte com exemplo | 40 |
| Figura 4 - Destaque das propriedades agrícolas onde ocorreu a ampliação das áreas de soja entre 2009 e 2013 | 42 |
| Figura 5 - Gráfico do uso e ocupação dos solos de Mato Grosso, representando a área total ocupada (tamanho da bolha) e o número de propriedades (eixo y), em 2013, e o crescimento médio anual entre 2008 e 2013 (eixo x) | 43 |
| Figura 6 - Resultado da análise de componentes principais (ACP). Mapa com a variação dos autovetores para os componentes 1 e 2..... | 52 |
| Figura 7 - Histograma com a distribuição de probabilidade da expansão de soja para cada modelo..... | 56 |
| Figura 8 - Boxplots da distribuição das probabilidades das áreas não convertidas versus as áreas convertidas em 2014..... | 58 |
| Figura 9 - Histograma com a dispersão da probabilidade nas áreas onde ocorreu a conversão em 2014..... | 59 |
| Figura 10 - Boxplots da probabilidade das áreas convertidas de soja para cada modelo testado | 62 |
| Figura 11 - Demonstração do poder de simulação de cada modelo pela curva Roc | 64 |
| Figura 12 - Mapas de calor com a dispersão da probabilidade de conversão para soja em cada modelo sobre Mato Grosso..... | 65 |

LISTA DE TABELAS

| | |
|---|----|
| Tabela 1 - Base de dados com as camadas de shapefiles utilizada para compor o grid de perímetro das propriedades..... | 30 |
| Tabela 2 - Total de unidades mínimas de análise (propriedades) por camada..... | 40 |
| Tabela 3 - Estatísticas da conversão das áreas para soja entre 2009 e 2013..... | 41 |
| Tabela 4 - Distribuição por decil das condicionantes ambientais das propriedades do Estado de Mato Grosso | 44 |
| Tabela 5 - Parâmetros utilizados para cálculo do custo das máquinas agrícolas de cada propriedade..... | 46 |
| Tabela 6 - Parâmetros utilizados para calcular o custo com implementos em cada fazenda | 46 |
| Tabela 7 - Parâmetros utilizados para cálculo do custo com mão de obra em cada fazenda | 47 |
| Tabela 8 - Tamanho médio das propriedades por ano e faixa de rentabilidade operacional teórica | 48 |
| Tabela 9 - Distribuição estatística das variáveis logísticas das propriedades de Mato Grosso em 2013..... | 49 |
| Tabela 10 - Análise de componentes principais para todas as variáveis do modelo..... | 53 |
| Tabela 11 - Estatísticas das probabilidades dos modelos testados para as áreas onde ocorreram ou não a conversão das áreas de soja | 57 |
| Tabela 12 - Impacto da variação de cada variável em cada modelo sobre a probabilidade de conversão para soja, medido em pontos percentuais | 61 |
| Tabela 13 - Diferença entre as estatísticas de probabilidade de conversão das áreas onde não ocorreram versus as áreas onde ocorreram a conversão para soja em 2014 | 63 |

1. INTRODUÇÃO

1.1. Considerações iniciais

Segundo a Organização de Cooperação e Desenvolvimento Econômico, entre 2012 e 2050, a população mundial deve crescer mais de 30%, atingindo 9,7 bilhões de habitantes (OECD, 2015). Como se espera que esse crescimento ocorra principalmente em países em desenvolvimento, a mesma organização também prevê um aumento importante da receita da população, gerando um incremento ainda maior da demanda por alimentos (70%), energia (80%) e água (55%).

Apesar desse aumento da demanda por alimentos, energia e água, Radeloff et al. (2012), projetando o uso e ocupação dos solos da área continental dos Estados Unidos, que atualmente é o maior produtor mundial de alimentos e energia, observaram uma tendência de queda de 16% das áreas agrícolas e de 13% das áreas de pastagens até 2051. Essa mudança do uso dos solos deve ocorrer em decorrência do crescimento de 79% das áreas urbanas e de 7% das áreas de floresta, indicando uma necessidade de contribuição maior de outras regiões do mundo na alimentação mundial.

Avaliando dez estudos sobre o potencial de uso e ocupação dos solos ao redor do mundo, Schimitz et al. (2014) concluíram que sete indicaram que a agricultura deve crescer entre 10% e 25% até 2050, comparando-se com dados de 2005, devendo ocorrer principalmente em áreas de pastagens da América do Sul e África Subsaariana.

Considerando que poucos países teriam capacidade de suprir esse aumento da demanda, a OECD aponta que o Brasil contribuirá com 40% dessas futuras necessidades da população mundial, passando a responder por 18% da produção mundial de grãos em 2050, contra os atuais 7%, corroborando as expectativas apontadas por Schimitz et al. (2014).

Tendo em vista às restrições quanto ao desmatamento de novas áreas, impostas pelo novo Código Florestal Brasileiro, regulado pela Lei n. 12.651, de 25 de maio de 2012, boa parte do incremento produtivo que o mundo demandará do Brasil poderá vir sem que sejam feitos novos desflorestamentos. Isso porque, entre a década de 1970 e o início dos anos 2000, além da abertura de áreas para a produção agrícola,

um volume ainda maior de áreas foi aberto para o cultivo de pastagens para a pecuária, e nos últimos anos essas áreas têm sido convertidas para a produção agrícola.

O Estado de Mato Grosso se destaca neste cenário, pois, apesar de ser o líder brasileiro na produção de diversos produtos agrícolas e pecuários, com destaque para o algodão (50%), milho (35%), soja (29%) e bovinos (15%), (CONAB, 2015; IBGE, 2015), ainda apresenta grande potencial de crescimento da produção agrícola. De acordo com o Instituto Mato-Grossense de Economia Agropecuária (Imea, 2015), dos 24 milhões de hectares de pastagens do Mato Grosso, 15 milhões de hectares poderiam ser convertidos em áreas de produção agrícola, resultando em um aumento de 160% da área plantada de soja na safra 2014/2015, que foi de 8,9 milhões de hectares.

Baseado nessas expectativas, uma série de estudos preveem o crescimento da produção agrícola do Brasil, em especial do Estado de Mato Grosso. Masuda e Goldsmith (2009), Mapa (2016) e Fiesp (2015) projetam para a próxima década, um crescimento anual da área de soja brasileira entre 0,80% e 2,65%. Já para Mato Grosso, Mapa (2016) e Imea (2015), estimam um crescimento anual da área plantada de soja mais acelerado para os próximos 10 anos, variando entre 2,97% e 4,81%.

A perspectiva de continuidade do aumento da produção agropecuária do Estado de Mato Grosso, em especial da cadeia de soja, é um alento para a economia local, uma vez que o setor do agronegócio responde por pouco mais de 50% do produto interno bruto estadual. Desse universo, a soja é sem dúvida o principal produto primário produzido em solo mato-grossense, representando também, coincidentemente, pouco mais de 50% do valor bruto da produção agropecuária.

Apesar da pujante produção agropecuária, o processo de ocupação do Estado de Mato Grosso é recente e se deu de forma rápida, o qual, aliado aos baixos níveis de investimento, colocam Mato Grosso como um dos Estados com o maior déficit de infraestrutura do País. O estudo Centro-Oeste Competitivo (Macrologística, 2013) estima que o custo de transporte na região centro-oeste em 2011 ultrapassava os R\$ 30 bilhões, representando mais de 8,0% do PIB regional, enquanto que na região Nordeste esse mesmo custo representa 6,0%, na região Sul, 5,7% e na região Sudeste, 4,5%.

Outro problema discutido na literatura é a análise dos impactos sobre os sistemas socioambientais, em especial diante do processo de desmatamento ocorrido em Mato Grosso nas últimas décadas, como apontado por diversos autores, como Anderson, Rojas e Shimabukuro (2003); Veldkamp e Lambin (2001); Weinhold e Reis (2008); Mann, Kaufmann et al. (2010); (2014)); Bowman, Soares-Filho et al. (2012); Verburg, Rodrigues Filho et al. (2014) e Simões, Pereira e Ferraz (2014). Com essas análises, é possível discutir as consequências da mudança do uso e ocupação dos solos, permitindo a criação de políticas e ações mitigatórias que promovam a conservação do meio ambiente e o bom uso dos recursos naturais.

Nesse contexto, os desenvolvedores de políticas públicas não têm a simples missão de promover o desenvolvimento regional, mas devem responder às questões de onde e em quais condições este desenvolvimento deve ocorrer. Isso porque, para que o governo consiga elaborar um bom planejamento estratégico, é fundamental realizar um diagnóstico preciso das causas e condições da expansão agropecuária em cada localidade.

De posse de um bom diagnóstico, os formuladores de políticas públicas podem dispor de informações suficientes para planejar um crescimento sustentável do Estado. Assim, espera-se que os investimentos, públicos e privados, ocorram onde exista uma maior demanda, promovendo o desenvolvimento econômico, social e ambiental, auxiliando em especial na redução do desmatamento ilegal e na preservação dos valiosos recursos naturais.

Sendo assim, para facilitar esse diagnóstico, é fundamental o desenvolvimento de modelos probabilísticos que forneçam aos gestores públicos, a tendência geográfica de expansão da área plantada de soja no Estado de Mato Grosso, em especial, em substituição às áreas de pastagens ou de remanescente florestal.

1.2. Tema, objetivos e justificativa

A probabilidade de expansão ou contração de um tipo de cobertura baseado no histórico de uso e ocupação dos solos é um tema amplamente explorado. Com o avanço global da consciência conservacionista e a constatação de desmatamentos na região Amazônica, o Brasil passou a ser alvo de estudos nesta área.

Oficialmente, é função do Instituto Brasileiro de Geografia e Estatística (IBGE)

produzir e analisar as informações estatísticas do uso e ocupação dos solos, mas algumas unidades de outros órgãos, como o Instituto Nacional de Pesquisas Espaciais (Inpe) e a Empresa Brasileira de Pesquisa Agropecuária (Embrapa), também se dedicam a esse tema.

Apesar dos avanços, a maior parte dos estudos sobre o tema limitam-se a analisar o ocorrido no passado, sendo poucos os que se propõem a analisar as possibilidades de mudança do uso dos solos, especialmente quando considerado o marco temporal de 2008, quando o novo código florestal brasileiro consolidou as ocupações rurais de todo o território nacional.

Considerando que a agricultura é a atividade econômica mais demandada pelo crescimento da população, visando a produção de alimentos, o que a faz competir por espaço com as florestas, exercendo enorme pressão sobre elas, a análise do território mato-grossense é especialmente importante, já que é o Estado de Mato Grosso é o maior produtor nacional de soja, tem a maior área nacional de pastagem e mais de 60% da vegetação original preservada, sendo uma das maiores áreas de floresta nativa do Brasil, sendo, portanto a região brasileira onde se esperam grandes mudanças do uso e ocupação dos solos.

Necessitamos, portanto, obter informações sobre as determinantes da expansão do uso dos solos da cultura da soja no Estado de Mato Grosso, sendo esse o tema desta dissertação, essencial para a formulação de ações de investimentos visando a maximização do retorno e a minimização dos impactos.

Uma forma de obtenção dessas informações se dá pela análise do comportamento do uso e ocupação dos solos de uma determinada região ao longo de um tempo predeterminado, identificando quais fatores tiveram maior influência sobre o processo de expansão da soja ocorrido, possibilitando-se inferir qual o caminho da produção agrícola em Mato Grosso e, conseqüentemente, direcionar as políticas de investimentos e ações que mitiguem o desmatamento, como sugerem vários autores, dentre eles, Aguiar, Câmara e Escada (2007); Bowman, Soares-Filho, et al. (2012) e Verburg, Rodrigues Filho et al. (2014).

Sendo assim, o objetivo geral desta dissertação é identificar a técnica de modelagem que mais se adapta ao estudo de probabilidade da mudança do uso e ocupação dos solos. Para tanto, serão apresentadas as técnicas de modelagem estatística, empírica e por painel com especialistas.

Como consequência do objetivo geral, os objetivos específicos desta dissertação são:

- i. Diferenciar a influência dos fatores intrínsecos às propriedades (fatores ambientais e localização), dos fatores relacionados ao mercado (questões econômicas e desenvolvimento microrregional) no processo de expansão da área plantada de soja;
- ii. Estudo de caso com elaboração de um mapa com os locais mais prováveis de conversão de pastagens ou outros usos para a produção de soja;
- iii. Discutir as vulnerabilidades ambientais e logísticas das áreas potenciais eventualmente apontadas pelo estudo;

1.3. Metodologia

A metodologia utilizada para a elaboração desta dissertação inicia com a definição dos objetivos a serem alcançados e com a revisão bibliográfica indicando os possíveis caminhos a serem percorridos, para a resolução do problema encontrado.

A primeira etapa constituiu no processo de mapeamento do perímetro das propriedades do Estado de Mato Grosso, após a definição dos critérios estabelecidos para a escolha dos bancos de dados a serem considerados.

Em seguida, foram apresentados os critérios considerados para a identificação da mudança do uso e ocupação dos solos, indicando no mapa base gerado na etapa anterior, os resultados específicos para a expansão das áreas de produção de soja, no período correspondente.

Na terceira etapa foram indicadas as possíveis variáveis de análise, tendo sido apresentadas as suas definições ou as respectivas metodologias de cálculo, para então plotar estas variáveis sobre o mapa base criado, formando o banco de dados para o estudo de caso.

Na quarta etapa, foram abordadas três alternativas de modelagem para a

construção de oito diferentes modelos probabilísticos, assim caracterizados: (i) três modelos construídos por um processo estatístico, utilizando-se a técnica de análise de componentes principais; (ii) quatro com variáveis selecionadas empiricamente; e (iii) um por painel com especialistas; tendo sido utilizada a técnica de regressão logística para estimar, para cada modelo, a probabilidade de conversão das áreas para a produção de soja.

Por fim, na quinta etapa foram descritas as técnicas utilizadas para a análise estatística descritiva dos modelos construídos na etapa anterior, com o objetivo de apontar aquele de maior acurácia.

1.4. Limitações

Os resultados deste trabalho estão limitados ao território do Estado de Mato Grosso, sendo restritas as extrapolações para outras regiões. O estudo também foi delimitado pelas variáveis (ambientais, logísticas e econômicas) consideradas na análise de cada modelo, deixando de lado uma série de fatores que podem gerar alguma influência sobre a expansão da soja.

Dentre os fatores que não foram analisados neste trabalho, estão os fatores socioeconômicos. A cultura de origem da população local é algo empiricamente destacado pelos especialistas, que sugerem que a origem da maioria das pessoas de uma comunidade – se vindas do Sul, Sudeste, Nordeste, Norte ou da própria região Centro-Oeste – interfere no tipo de atividade e na velocidade do desenvolvimento regional, mas devido à falta de informações, não foram exploradas neste estudo. Também não foram utilizados os índices de desenvolvimento humano de cada município e outras informações gerais, como renda per capita.

Além disso, o estudo está restrito à análise da expansão da cultura da soja, não respondendo a possíveis fatores de retração da própria cultura ou mesmo de expansão de outras atividades agrícolas. Mesmo a previsão de expansão de culturas como o milho, cujo plantio em Mato Grosso ocorre em sua ampla maioria sobre áreas de soja, não podem ser consideradas como tendo a mesma probabilidade de ocorrência apurada neste trabalho, já que esta cultura tem um zoneamento climático diferente e um menor estímulo de mercado, devido ao menor valor agregado, quando

comparado à soja.

1.5. Estrutura do trabalho

Esta dissertação está organizada em 6 capítulos. O capítulo 1 refere-se à introdução. Além de contextualizar o cenário agrícola e de uso e ocupação dos solos, são definidos o tema, os objetivos e justificativas do trabalho, é apresentado o resumo da metodologia e as limitações do estudo.

O capítulo 2 traz a revisão bibliográfica apresentando as noções gerais sobre o tema, as propostas metodológicas adotadas por diversos autores e a descrição dos estudos que serviram de base para a construção do banco de dados utilizados neste trabalho.

Os procedimentos metodológicos adotados nesta dissertação são apresentados no capítulo 3, onde contam a descrição dos procedimentos básicos de mapeamento, coleta de dados da mudança do uso e ocupação dos solos, definição dos critérios de modelagem e das análises estatísticas adotadas.

No capítulo 4 são apresentados os resultados obtidos para o estudo de caso, tendo sido apresentados o mapa base do estudo, os resultados da evolução do uso e ocupação dos solos, a análise descritiva das variáveis e os resultados do processo de modelagem, bem como uma avaliação da acurácia desses modelos.

O capítulo 5 apresenta as discussões sobre os resultados do estudo de caso, apontando além das tendências extraídas de um processo de análise empírica dos resultados, uma análise conjuntural do período estudado e os possíveis impactos dessa conjuntura sobre os resultados obtidos.

Por fim, no capítulo 6, foram apresentadas as considerações finais, destacando-se as principais conclusões sobre o processo de expansão e a probabilidade de sua continuidade. Também foram identificados os fatores que influenciaram o processo de expansão, discutida a influência dos fatores intrínsecos e externos (mercado), e analisados os possíveis impactos ambientais decorrentes desse processo. Por fim, foram apresentadas as limitações e sugestões de análises futuras.

2. ESTUDOS SOBRE O USO E OCUPAÇÃO DOS SOLOS

Esta seção consiste da revisão bibliográfica realizada, a qual fornece subsídios para o conhecimento dos tipos de variáveis geralmente empregadas nos estudos de uso e ocupação dos solos no Brasil e no mundo (2.1), das características do processo de mapeamento do uso e ocupação dos solos (2.2), dos métodos adotados neste estudo para a identificação do uso e ocupação dos solos (2.3), dos métodos de seleção das variáveis a serem analisadas (2.4) e finalmente dos modelos empregados para estimar a probabilidade de mudança do uso dos solos (2.5).

2.1. A mudança do uso e ocupação dos solos na literatura

A análise e a predição do uso e ocupação dos solos é tema de diversos estudos mundo afora, dadas as suas relevâncias no planejamento regional das políticas de desenvolvimento econômico, social e ambiental. As predições têm mostrado eficácia, o que aumenta os interesses acadêmico e prático sobre esse tipo de abordagem. Um estudo que corrobora essa ideia foi apresentado por Wear e Bolstad, (1998), quando construíram um modelo de longo prazo (40 anos) para a predição do uso e ocupação dos solos de quatro localidades na região Sul dos Apalaches (EUA), obtendo uma taxa de acerto de 68% a 89%.

Em um estudo sobre o uso e ocupação dos solos do departamento de Rhones, na França, Chakir e Parent (2009) concluíram que a qualidade dos solos e a distância de redes de rodovias aumentavam a probabilidade de ocorrência de áreas de uso agrícola em detrimento de áreas urbanas, enquanto que uma maior renda de um município ampliava a probabilidade de uso dos solos como áreas urbanas.

A degradação dos solos também pode ser um direcionador do uso e ocupação dos solos. Bakker et al. (2005) analisaram a porção oeste da região de Levos na Grécia e concluíram que a erosão dos solos na região foi o principal direcionador do abandono de terras, enquanto que fatores como a profundidade dos solos e a declividade direcionaram a implantação de novas áreas agrícolas de produção de grãos.

A probabilidade de mudança do uso e ocupação dos solos também pode ser afetada também pela presença de indústrias. Após a instalação de usinas de produção de etanol de milho em diversas regiões do meio-oeste americano, Miao (2011)

constatou um aumento médio de 5,9 pontos percentuais na probabilidade de ocorrência do plantio de milho, variando para mais em regiões onde a proporção de milho era média e para menos onde essa proporção estava acima da média.

Serneels e Lambin (2001), estudando o uso e ocupação dos solos de agricultura familiar no Quênia, constataram que o ambiente socioeconômico regional também pode influenciar no uso e ocupação dos solos, identificando como fatores predominantes a proximidade de fontes de água permanente, a aptidão agrícola, a proximidade de mercados turísticos e o acesso a serviços sociais.

O estudo conduzido na China por Jiang et al. (2013) apontou que a expansão das cidades e o crescimento do PIB industrial podem influenciar negativamente a intensidade do uso das terras pela agricultura, tendo sido os responsáveis pela queda na atividade agrícola naquele país.

Na região Norte de Idaho, nos Estados Unidos, Pocewicz et al. (2008) estudaram a intenção declarada do uso e ocupação dos solos. Os autores apontaram que a introdução de intenções individuais no modelo de projeção do uso e ocupação dos solos melhorou as previsões, antes baseadas somente em tendências temporais, evitando assim erros de classificação de imagens.

Analisando o mercado de terras da Europa, Ustaoglu et al. (2016) determinaram uma relação entre o valor da produção agrícola e o preço das terras, conseqüentemente, os autores estabeleceram uma ligação com a mudança do uso e ocupação dos solos, sugerindo o uso desse parâmetro econômico como um bom preditor da conversão do uso dos solos.

No Brasil, diversos fatores são apontados como catalisadores do processo de ocupação das terras da Amazônia e do Cerrado brasileiros. Analisando os dados do histórico de ocupação dos solos da Amazônia brasileira, Aguiar, Câmara e Escada (2007) concluíram que ela se dá preferencialmente próximo às cidades e rodovias, principalmente aquelas que ligam essas regiões aos grandes centros consumidores. Porém, as condições climáticas e o perfil fundiário também ajudam a explicar o modelo de ocupação regional.

Jasinski et al. (2005) avaliaram a efetividade de cinco fatores de influência para o uso e ocupação dos solos de Mato Grosso entre 2001 e 2003, sendo eles a declividade, tipo de solo, precipitação em novembro, distância de rodovias pavimentadas e cobertura vegetal anterior à conversão. O modelo apresentado por

esses autores apontou o uso anterior da terra como a principal variável explicativa para a criação de áreas agrícolas em Mato Grosso, sendo que mais de 70% das áreas convertidas entre 2001 e 2003 estavam ocupadas por pastagens ou remanescente de cerrado. Além disso, os autores também apontaram a declividade e a distância de rodovias pavimentadas como variáveis explicativas secundárias.

Obviamente alguns fatores geográficos, como localização e tipo de solo, podem interferir não apenas na conversão, mas também na renda das propriedades. Este tema foi bem abordado por Bowman, Soares-Filho, Merry, Nepstad e Rodrigues (2012), que indicaram que a renda da bovinocultura de corte não é competitiva com a renda da soja em áreas bem localizadas e com infraestrutura, o que estimula a especulação imobiliária podendo acelerar o processo de conversão, de acordo com a flutuação de preços deste mercado.

Segundo Aguiar (2006), o fator mais importante para capturar os padrões espaciais da expansão das novas fronteiras seria a ligação com os mercados nacionais. Por sua vez, a interação dessas ligações com os fatores biofísicos e socioeconômicos é que provoca uma dinâmica inter-regional heterogênea. Corroborando essa análise, Mann et al. (2010), estudando a conversão de terras em Mato Grosso, apresentaram um modelo indicando que a renda das propriedades é a variável de maior impacto para a ocupação da soja, tendo, inclusive, maior impacto que variáveis como a distância dessas áreas até rodovias pavimentadas.

Analisando o impacto dos preços, Verburg, Rodrigues Filho et al. (2014) também concluíram que os preços das commodities influenciam diretamente na ocupação de terras, podendo, em última análise, motivar o aumento do desmatamento na Amazônia. Em um segundo estudo, Mann, Kaufmann, et al. (2014) indicam que, quando o lucro da pecuária na fronteira da Amazônia aumenta cerca de cem dólares por hectare, a probabilidade de conversão para pasto dessas áreas na fronteira da Amazônia aumenta de 8,6% para 11,1%, citando mais uma vez a importância da variável renda nos estudos de uso e ocupação dos solos.

O valor potencial da renda de uma área e, conseqüentemente, seu potencial de conversão, dependem de fatores complexos, como o ambiente de produção (solo, clima e insumos), mercado e políticas socioeconômicas (Mann M. L., et al., 2010).

Alguns trabalhos, como os de Jasinski, Morton et al. (2005), Aguiar, Câmara e Escada (2007), Mann, Kaufmann et al. (2014) e Verburg, Rodrigues Filho et al. (2014),

indicarem os fatores que direcionaram o uso e ocupação dos solos de Mato Grosso. No entanto, nenhum explorou uma base de dados recente, especialmente após o ano de 2008, que teve como pano de fundo uma conjuntura diferenciada com a aprovação do novo Código Florestal que trouxe a admissão de ferramentas como o Cadastro Ambiental Rural (CAR), que mapeou o perímetro das propriedades, e o Plano de Recuperação Ambiental (PRA), que mapeou os ativos e passivos ambientais (Almeida, Tiosso, & Silva, 2014).

Prova dessa mudança conjuntural foi apontada no projeto Terra Class (Embrapa e Inpe, 2012) que indicou que entre 2010 e 2012, apenas 2% do crescimento da área agrícola se deu sobre áreas de desmatamento, sendo que a maioria absoluta se deu sobre áreas de pastagens.

O texto de discussão apresentado por Carvalho et al. (2016) também concluiu que entre 2006 e 2011, a contribuição do desmatamento para o crescimento do PIB da região amazônica foi mínima, tendo sido a agregação tecnológica na produção agrícola o principal fator. Essa conclusão difere do apontado por trabalhos antigos, como nos artigos desenvolvidos por Anderson, Rojas e Shimabukuro (2003) e Rivero et al. (2009), que indicavam a produção de soja e de bovinos de corte como a principal responsável pelo desmatamento no Mato Grosso e na Amazônia Legal.

2.2. Características das bases de mapeamento do uso dos solos

Devido à escassez e ao custo de construção de bases geoespaciais, a maioria dos estudos sobre o uso e ocupação dos solos utiliza delimitações geográficas regionais, como os municípios. Como exemplo, destacam-se dois trabalhos, Verburg et al. (2014) e Verburg et al. (2014), que tratam da ocupação dos solos e do desmatamento no Norte de Mato Grosso e Sul do Pará, em que foram utilizados como unidade de análise, as divisas dos municípios.

Entretanto, como argumentaram Chakir e Parent (2009), a utilização de parcelas maiores limita a heterogeneidade espacial, uma vez que agrega fatores importantes, como tipo de solo, relevo, clima, etc. A análise de uso e ocupação dos solos desses autores partiu de um levantamento espacial feito de um grid de 12 x 12 quilômetros. Já Aguiar (2006) utilizou como unidade geográfica de análise um grid formado por quadrados de 25 x 25 quilômetros, modelo no qual Espindola et al. (2012) basearam suas análises.

Mann et al. (2014) utilizaram como unidade mínima de análise, imagens de satélites de Mato Grosso, Amazonas, Pará, Rondônia e Tocantins, com resolução espacial de 232 metros. Jasinski et al. (2005) também utilizaram pixels de aproximadamente 250 metros para analisar o uso e ocupação dos solos de Mato Grosso. Essa dimensão foi adotada por ser o padrão de cada pixel da imagem gerada pelo sensor Modis, presente nos satélites Terra e Aqua.

Pocewicz et al. (2008) também trabalharam com pixels em um levantamento do uso e ocupação dos solos do Estado de Idaho, nos EUA. Porém, os autores conseguiram uma precisão maior (0,6 hectare) utilizando imagens do satélite Landsat, cujo tamanho dos pixels de cada imagem é menor que os das imagens do sensor Modis.

Seguindo a mesma metodologia, Espindola et al. (2012) também utilizaram pixel do satélite Landsat como unidade mínima de análise. No entanto, essas imagens são repetidas com uma frequência menor, gerando uma maior probabilidade de falhas nas observações devido à ocorrência de nuvens, o que fez com que cerca de 5% das imagens precisassem ser descartadas.

2.3. Levantamento do uso e ocupação dos solos

O levantamento do uso e ocupação (cobertura) dos solos era feito historicamente, quase que exclusivamente, por pesquisa censitária, realizado oficialmente no Brasil pelo Instituto Brasileiro de Geografia Estatística (IBGE). No entanto, a partir da década de 90, o avanço da capacidade de processamento dos computadores, a disponibilização de dados de imagens de satélites e o avanço da conectividade da internet, popularizaram os estudos sobre o uso e ocupação dos solos.

Existem métodos que integram as duas abordagens de levantamento do uso e ocupação dos solos. O trabalho desenvolvido por Aguiar (2006) levou em consideração dados obtidos por sensoriamento remoto, realizado pelo Instituto Nacional de Pesquisas Espaciais (INPE) em 1997, e também os dados do Censo Agropecuário de 1996, realizado pelo Instituto Brasileiro de Geografia e Estatística (IBGE). A autora explicou que os dados do sensoriamento remoto resultaram em uma classificação geral do uso dos solos, tendo sido utilizados os dados do censo agropecuário para estabelecer a proporção de ocupação de cada cultura específica.

Espindola et al. (2012) utilizaram a mesma abordagem; porém, além das imagens de 1997 e do Censo de 1996, também empregaram imagens de satélite de 2007 e os dados do Censo Agropecuário de 2006. Já Chakir e Parent (2009), na França, utilizaram o Projeto Teruti, que faz uso de imagens aéreas em conjunto com um questionário, para identificar com detalhe 81 tipologias de uso dos solos daquele país.

Pocewicz et al. (2008) também se valeram da abordagem mista entre censo e uso de imagens para avaliar o uso dos solos em Idaho, nos EUA, nos anos de 1985, 1992, 2000 e 2003. Além de contar com as imagens do satélite Landsat, com imagens aéreas e com a coleta de coordenadas de campo com o respectivo uso dos solos para treinar o software, os autores distribuíram um questionário para os produtores da região.

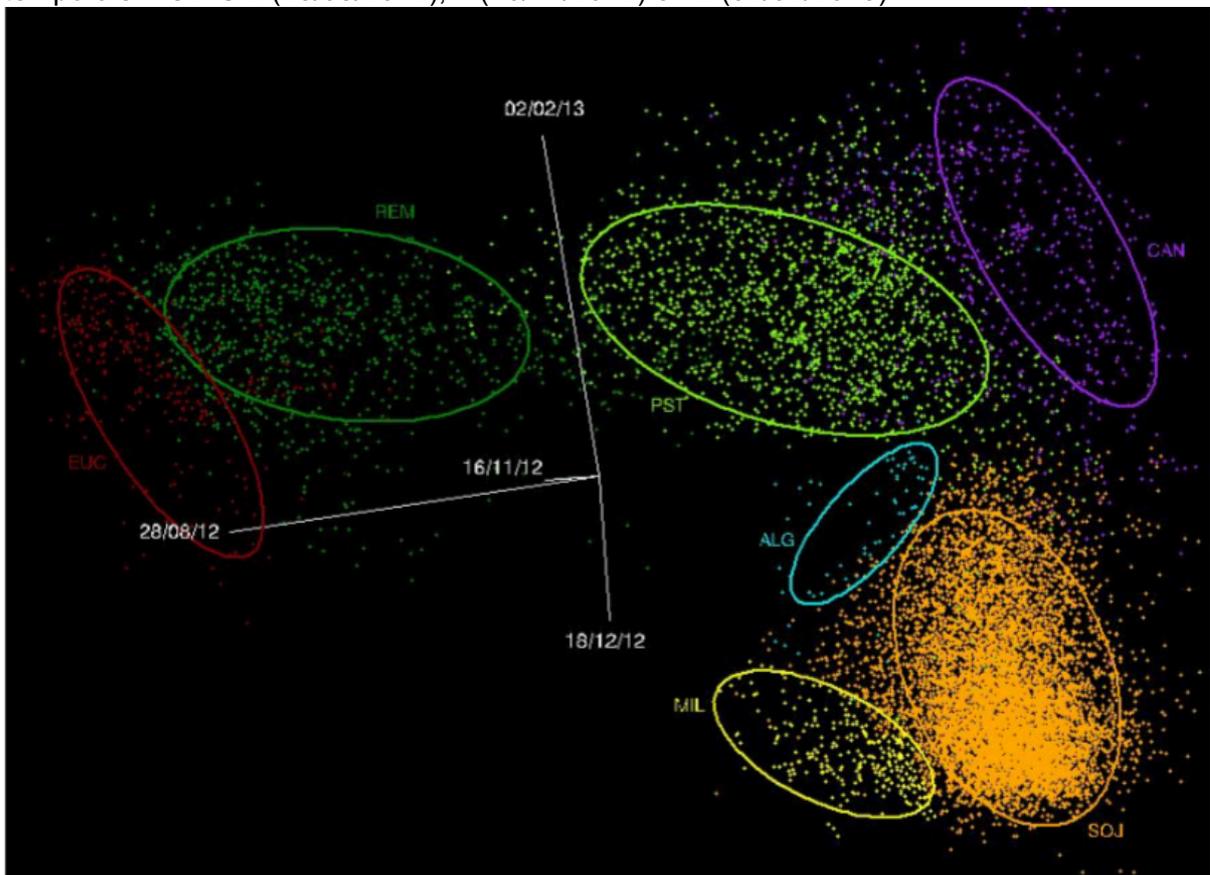
Autores como Anderson et al. (2003), Jasinski et al. (2005), Mann et al. (2010), Mann et al. (2014), Simões et al. (2014) utilizaram modelos computacionais, baseados em imagens de satélites, para a identificação do uso e ocupação dos solos.

Seguindo essa metodologia de modelos computacionais baseados em imagens de satélite, o Projeto Siga-MT (Sistemas de Informações Geográficas Agropecuárias de Mato Grosso), desenvolvido por Imea e Sinoptica (2014), foi o método escolhido para ser utilizado nesta dissertação. No referido Projeto, foi feita a classificação do uso e ocupação agrícola dos solos de Mato Grosso, identificando as principais atividades de uso dos solos, dentre elas: algodão, soja, milho, arroz, cana-de-açúcar, eucalipto, teca, seringueira, pasto, remanescente florestal, áreas irrigadas por pivô e outros usos.

Para a classificação das imagens, o Projeto Siga-MT (Imea e Sinoptica, 2014) utilizou imagens de 2008 a 2014 dos sensores MODIS (a bordo dos satélites Terra e Aqua) e ETM+ (a bordo dos satélites Landsat 7 e Landsat 8). Apesar da pior resolução do sensor Modis em relação ao sensor ETM+, que é de 250 metros para o primeiro e 30 metros para o segundo, foram utilizadas as imagens do sensor MODIS pela alta frequência temporal de coleta de dados, pois no caso do sensor Modis as imagens são diárias e as imagens do sensor EMT+ são quinzenais. Esta alta frequência de imagens do sensor Modis evita a falta de imagens pela ocorrência de nuvens. Com as imagens do sensor Modis, foram calculados os seguintes índices: índice de vegetação por diferença normalizada (NDVI) e o índice de vegetação realçado (EVI), que foram utilizados na classificação não supervisionada.

Para realizar o treinamento de classificação não supervisionada, foram realizados levantamentos de campo durante o mês de janeiro de 2013, em todo o Estado de Mato Grosso para a coleta de 25 mil pontos-coordenadas. Desse total, 70% foram utilizados para o treinamento e 30% para testar a acurácia final do trabalho de mapeamento do Projeto Siga-MT. Com os dados dos pontos-coordenadas, foi feito o esquema de classificação caracterizando a curva de desenvolvimento da vegetação de cada cultura e, posteriormente, a separação das classes, conforme a Figura 1.

Figura 1 - Resultado do projeto Siga-MT (Imea e Sinoptica, 2014) apresentando o visualizador n-D agrupando as amostras de campo mais representativas de cada cultura, com as bandas temporais MODIS 2 (28/08/2012), 7 (16/11/2012) e 12 (02/02/2013)



Fonte: Imea e Sinoptica (2014)

As imagens NDVI e EVI, as estatísticas de separabilidade das classes, mais o mapa de declividade (extraído do projeto SRTM da Nasa), foram plotados no classificador *Support Vector Machine* (SVM), servindo de base para a definição do uso e ocupação dos solos. Como as imagens ETM+ têm uma resolução espacial de 30 metros, que é melhor que a resolução do sensor Modis, de 250 metros, elas foram utilizadas com vistas a ter uma classificação supervisionada melhorada *a posteriori*. Até 2013, apenas o satélite Landsat 7 estava disponível, cuja frequência de imagens

era de uma a cada 16 dias (caindo para uma a cada 8 dias em 2013, quando o satélite Landsat 8 entrou em órbita), não sendo suficiente para gerar uma massa de classificação automatizada.

Com o trabalho de classificação concluído, foi feita a comparação com os 30% de dados de campo guardados, para testar a acurácia do processo de mapeamento, representados pela matriz de confusão. Na Figura 2, é possível observar o resultado da matriz de confusão da classificação final do Projeto Siga-MT, que teve nível médio de concordância total de quase 94%, sendo que para a soja, cultura analisada neste trabalho, o índice de concordância ficou próximo de 97%.

Figura 2 - Resultado do projeto Siga-MT (Imea e Sinoptica, 2014) apresentando o quadro da matriz de confusão do cruzamento entre os dados reais de uso e ocupação levantadas a campo e o uso e ocupação dados pelo procedimento de classificação do projeto.

| | ALG | ARR | CAN | EUC | MIL | PST | REM | SER | SOJ | TEC | URB | Total |
|--------------------|-------|-------|-------|-------|------|-------|-------|-------|-------|-----|---------------|--------|
| ALG | 86.21 | 0 | 0 | 0 | 1.6 | 0.08 | 0 | 0 | 0.63 | 0 | 0 | 1.14 |
| ARR | 0 | 80.49 | 0 | 0 | 0 | 0.04 | 0 | 0 | 0 | 0 | 0 | 0.18 |
| CAN | 0 | 0 | 93.83 | 0 | 0.8 | 0.66 | 0.02 | 0 | 0.41 | 5 | 0 | 1.54 |
| EUC | 0 | 0 | 0 | 74.65 | 0 | 0.08 | 0.23 | 31.58 | 0.24 | 10 | 0.62 | 0.57 |
| MIL | 0 | 0 | 0 | 0 | 78.4 | 0.17 | 0 | 0 | 0.28 | 0 | 0 | 0.69 |
| PST | 0 | 12.2 | 2.47 | 11.27 | 2.4 | 92.41 | 6.78 | 0 | 1.23 | 0 | 29.85 | 15.57 |
| REM | 1.14 | 0 | 0.82 | 11.27 | 0 | 4.32 | 92.76 | 0 | 0.28 | 0 | 2.15 | 31.53 |
| SER | 0 | 2.44 | 0 | 0 | 0 | 0 | 0.02 | 68.42 | 0 | 0 | 0 | 0.15 |
| SOJ | 12.64 | 4.88 | 2.88 | 2.82 | 16.8 | 1.91 | 0.2 | 0 | 96.91 | 0 | 0.62 | 47.3 |
| TEC | 0 | 0 | 0 | 0 | 0 | 0.04 | 0 | 0 | 0 | 85 | 0 | 0.1 |
| URB | 0 | 0 | 0 | 0 | 0 | 0.29 | 0 | 0 | 0.02 | 0 | 66.77 | 1.23 |
| Total | 100 | 100 | 100 | 100 | 100 | 100 | 100 | 100 | 100 | 100 | 100 | 100 |
| Concordância Total | | | | | | | | | | | (17318/18432) | 93.96% |
| Índice Kappa | | | | | | | | | | | | 0.9066 |

Fonte: Imea e Sinoptica (2014)

O resultado final do trabalho elaborado por Imea e Sinoptica (2014) foi um mapa vetorial para os anos de 2008, 2009, 2010, 2011, 2012, 2013 e 2014 com nível de precisão semidetalhado, com uma escala de 1:50.000 nos levantamentos das áreas de pastagem e de remanescente florestal e de 1:25.000 para as áreas de soja e demais usos.

2.4. Definição e seleção das variáveis

A seleção de variáveis feita por Aguiar (2006), para estudar o que estava correlacionado com a mudança do uso e ocupação dos solos na região amazônica, foi inicialmente extraída de revisões de literatura e estudos empíricos. Desse processo, foram pré-selecionadas variáveis socioeconômicas e ambientais, que por sua vez selecionou 50 variáveis através de um processo iterativo, dividindo-as em sete grupos: Acessibilidade a mercados; Atratividade econômica; Demográficos; Tecnológicos; Estrutura agrária; Políticas públicas; Ambientais. Para determinar as variáveis relevantes, a autora utilizou o modelo de regressão *spacial lag*, verificando a importância relativa de cada fator.

Além da revisão de literatura para entender o uso e ocupação dos solos e predefinir variáveis de estudo, Jasinski et al. (2005) selecionaram variáveis em Mato Grosso através de entrevistas estruturadas com agricultores locais, que apontaram empiricamente quais fatores os motivaram a estabelecer sua produção no local.

Alguns autores utilizaram ferramentas estatísticas para selecionar as variáveis que iriam compor o modelo. Dentre eles, Pocewicz et al. (2008), utilizaram o modelo *random forests regression trees* para testar o melhor dentre quatro diferentes modelos de regressão (modelos lineares generalizados (GLM) com Poisson; GLM (modelos de Tobit); regressão logística ordinal; regressão geograficamente ponderada (GWR) com Distribuições de Poisson e Gaussiana), além de um modelo geral com a técnica de *Kriging* e outro com a técnica de *Bootstrapping*.

Espindola et al. (2012), para selecionarem as variáveis que mais explicavam o desmatamento na região amazônica, utilizaram a técnica de regressão linear simples e, após aplicarem testes para verificar a autocorrelação espacial para cada variável, também construíram um modelo de regressão espacial com *lags* de diferença.

Apesar de pouco utilizada nesse tipo de trabalho, a análise de componentes principais (ACP) também pode ser utilizada para selecionar variáveis. Segundo Varella (2008), a ACP é uma técnica estatística multivariada associada à redução de massa de dados, transformando um conjunto de variáveis originais em outro conjunto de variáveis de mesmo número de dimensões, chamado de componentes principais. A análise agrupa indivíduos de uma população de acordo com a variância das variáveis em estudo.

A determinação dos componentes principais é dada pela sequência da resolução da matriz X (equação 10), onde existe o cruzamento das variáveis (p) e indivíduos (n) de uma determinada população (π). A partir dessa matriz X é construída

a matriz S (equação 11), que é simétrica em função do número de variáveis p , representando a covariância dessas variáveis. Com a resolução da matriz S (equação 12), tem-se p raízes chamadas de autovalores (λ), cuja soma é igual a 1 (equação 13). Cada autovalor (λ) tem seus autovetores (\tilde{a}) (equação 14). Por fim, o cálculo do peso de cada variável (w) advém da divisão dos autovetores (\tilde{a}) pela variância de cada variável (equação 15).

$$X = \begin{bmatrix} x_{11} & x_{12} & \dots & x_{1p} \\ \vdots & \vdots & \dots & \vdots \\ x_{n1} & x_{n2} & \dots & x_{np} \end{bmatrix} \quad (10)$$

$$S = \begin{bmatrix} \hat{V}ar(x_1) & \hat{C}ov(x_1x_2) & \dots & \hat{C}ov(x_1x_p) \\ \hat{C}ov(x_2x_1) & \hat{V}ar(x_2) & \dots & \hat{C}ov(x_2x_p) \\ \vdots & \vdots & \ddots & \vdots \\ \hat{C}ov(x_px_1) & \hat{C}ov(x_px_2) & \dots & \hat{V}ar(x_p) \end{bmatrix} \quad (11)$$

$$\det[S - \lambda I] = 0 \text{ ou } |S - \lambda I| = 0 \quad (12)$$

$$\lambda_1 > \lambda_2 > \lambda_3 > \dots > \lambda_p \quad (13)$$

$$\tilde{a}_i = \begin{bmatrix} a_{i1} \\ a_{i2} \\ \vdots \\ a_{ip} \end{bmatrix} \quad (14)$$

$$w_1 = \frac{a_{11}}{\sqrt{\hat{V}ar(X_1)}}, w_2 = \frac{a_{12}}{\sqrt{\hat{V}ar(X_2)}}, \dots, w_p = \frac{a_{1p}}{\sqrt{\hat{V}ar(X_p)}} \quad (15)$$

2.5. Modelagem da mudança do uso e ocupação dos solos

Os modelos probabilísticos de uso e ocupação dos solos geralmente se baseiam em modelos de escolhas discretas para explicar a escolha entre duas categorias de uso da terra, como os modelos probit ou logit binomial. No entanto, quando o desejo é modelar a possibilidade de vários usos da terra, são mais aplicados os modelos logit multinomial ou logit aninhado (Chakir & Parent, 2009).

O modelo logit pressupõe a independência espacial das variáveis, por isso é

mais simples e frequentemente mais adotado que o modelo probit. Alguns dos autores que conseguiram aplicar o modelo probit para o uso e ocupação dos solos foram Chakir e Parent (2009), que estudaram a dependência espacial da escolha de quatro tipos de usos da terra por parte de produtores da França.

Já Aguiar (2006) utilizou o modelo de regressão *spacial lag*, que considera a exploração dos padrões globais de autocorrelação espacial no conjunto de dados. Como o modelo pressupõe que o processo espacial é estacionário, isso implica na captura dos padrões de autocorrelação em um único termo de regressão.

Garret et al. (2013) seguiram um caminho semelhante; após gerarem um modelo de regressão múltipla geral, testaram a correlação espacial dos erros e ao verificarem a correlação espacial desses, geraram novos modelos com os devidos descontos dos lags de autocorrelação espacial.

Já Pocewicz et al. (2008), além de utilizarem uma série de regressões selecionadas pelo modelo *random forests trees*, como citado na seção anterior, também aplicaram um questionário aos produtores, perguntando suas intenções de modo do uso dos solos e também fizeram projeções com ferramentas clássicas de séries temporais.

Observando a conversão de áreas de pastagem na região amazônica, Mann et al. (2014) utilizaram um modelo de regressão logística espacial para estimar a probabilidade de conversão de pastagens.

Assim como no presente trabalho, Jasinski et al. (2005) empregaram a regressão logística múltipla para avaliar a probabilidade da expansão da soja no Estado de Mato Grosso, escolhido pela capacidade de analisar variáveis dicotômicas dependentes.

3. PROCEDIMENTOS METODOLÓGICOS

A classificação metodológica deste trabalho foi definida seguindo os critérios estabelecidos por Gil (1999). Assim, para o desenvolvimento do estudo será realizada uma pesquisa quantitativa no que se refere à abordagem e aplicada quanto à natureza, que consiste em estudos de razão de ordem prática. Além disso, conforme o autor, quanto aos objetivos, é uma pesquisa exploratória, uma vez que visa proporcionar uma maior familiarização do problema, permitindo a descoberta de intuições ou a construção de hipóteses.

No que tange aos procedimentos, é um estudo de caso, visto que se trata de um contexto econômico e regional específico e que, dada a sua complexidade, não permite a realização de experimentos para a sua análise. Para isso, foram analisadas as mudanças ou não mudanças do uso e ocupação dos solos em relação a uma série de fatores qualitativos e quantitativos ligados a questões ambientais, agronômicas, econômicas e logísticas de cada unidade fundiária.

3.1. Definição das bases do processo de mapeamento

Como cada unidade geográfica tem características ambientais, agronômicas, econômicas e logísticas próprias, o primeiro passo da pesquisa foi definir a unidade de análise mínima e extrair os valores das áreas que tiveram ou não seu uso e ocupação alterados.

Raramente são encontrados estudos que consideraram como unidade fundiária o perímetro das propriedades agrícolas, já que a base de dados correspondente não costuma estar disponível, sendo necessário requisitar a órgãos reguladores do Governo.

No entanto, foi considerado como unidade fundiária neste trabalho, o perímetro das propriedades agrícolas de Mato Grosso. A partir dessa definição, foram levantados os fatores econômicos ligados à escala de produção e uso da terra, além dos dados de fatores ambientais, agronômicos e logísticos médios de cada unidade fundiária.

Como existem inúmeras plataformas de cadastro de propriedades e nem todas têm o perímetro das propriedades cadastrado em uma base fundiária oficial, foram sobrepostas diversas bases para que permitissem identificar o maior número de

propriedades possível para Mato Grosso. O uso de diferentes bases de dados de cadastro de perímetro de propriedades traz consigo erros básicos de topologia e de sobreposição. Com o auxílio do *software* Arc Gis, os erros de topologia foram corrigidos e as sobreposições eliminadas, sendo então possível criar um grid de propriedades a ser utilizado no estudo.

Na Tabela 1, é apresentada a sequência de camadas consideradas para a eliminação das sobreposições, sendo a camada 1 a inferior e a camada 8 a superior. Dessa forma, uma informação da camada 8 irá sobrepor qualquer outra informação. Na prática, se existe, por exemplo, uma terra indígena (camada 8) sobre uma unidade de conservação florestal (camada 7), a área de intersecção dessas camadas será considerada como sendo terra indígena, por ser a camada superior, e assim por diante.

Tabela 1 - Base de dados com as camadas de shapefiles utilizada para compor o grid de perímetro das propriedades

| Camada | Nome | Fonte | Ano referência |
|---------------|--|--------------|-----------------------|
| 1 | Áreas não cadastradas em nenhuma base | | |
| 2 | Perímetro dos municípios do Estado (Mun.) | (IBGE) | 2012 |
| 3 | Cadastro Ambiental Rural (CAR) | (Sema-MT) | 2014 |
| 4 | Licença Ambiental Única (LAU) | (Sema-MT) | 2014 |
| 5 | Base de propriedades georreferenciadas (GEO) | (Incra) | 2014 |
| 6 | Base de Áreas de Assentamento Rural (ASR) | (Incra) | 2014 |
| 7 | Unidades de Conservação Florestal (UCF) | (MMA) | 2014 |
| 8 | Unidades de Terras Indígenas (UTI) | (Funai) | 2014 |

Fonte: Elaborado pelo autor

As três últimas camadas do grid de propriedades (ASR, UCF e UTI) foram inseridas apenas para que as áreas correspondentes a elas fossem excluídas do campo de análise deste trabalho. Isso porque, nos casos da UCF e UTI, não é permitido o seu uso comercial, e, no caso da ASR, a dimensão das unidades produtivas é extremamente pequena, não sendo viável o plantio de soja, informação de interesse deste artigo. No entanto, as áreas de pequenas dimensões localizadas fora dos assentamentos rurais foram consideradas, já que, diferentemente, das áreas de assentamento rural, podem ser arrendadas ou incorporadas às áreas adjacentes,

tornando-as viáveis para a produção de soja.

As camadas de áreas de propriedades privadas devidamente registradas (GEO, LAU e CAR) foram priorizadas nessa sequência devido ao alto grau de precisão dessas informações e ao volume de ocorrência. No caso do comparativo entre GEO (5) e LAU (4), foi dada a preferência ao GEO (5), devido à sua maior ocorrência, já que na prática, a obtenção do GEO (5) é o primeiro passo para se obter a LAU (4). Tanto o GEO (5) quanto a LAU (4) foram priorizados no comparativo com o CAR (3), devido à sua menor precisão, que não exige mapeamento com grande exatidão, levando, portanto, a maiores erros de sobreposição entre propriedades que possuem apenas o CAR (3).

As áreas não cadastradas em nenhuma base, que compuseram a camada 1, foram divididas aleatoriamente, sobrepondo-se uma malha com quadrados de 10 mil hectares, as quais foram identificadas como áreas não mapeadas (ANP). Por ter sido sobreposta pelas demais camadas, após serem excluídas as sobreposições, a maioria dessas áreas ficou com um tamanho final menor que 10 mil hectares.

Além de permitir a criação de uma base funcionalmente realista, essa divisão também permite uma melhor análise dos fatores geográficos do uso e ocupação dos solos, já que fragmenta áreas imensas antes ligadas por caminhos tortuosos. A decisão do tamanho máximo desses quadrados (10 mil hectares) foi estabelecida empiricamente, buscando preservar o poder de correlação espacial e ao mesmo tempo evitar fragmentações excessivas que, conseqüentemente, aumentariam o banco de dados e o esforço computacional da análise.

3.2. Critérios para a identificação da mudança do uso e ocupação dos solos

Com o grid de propriedades pronto, foi consultada a base de dados do Projeto Siga-MT, cedida pelo Imea (2015), plotando-se ano a ano, para o período de 2008 a 2013, a dinâmica do uso e ocupação dos solo.

Cruzando-se os mapas dos diferentes anos, foi então possível, identificar quais propriedades ainda possuíam potencial para conversão para a soja, ou seja, cuja área agricultável não estava totalmente ocupada por soja. Da mesma forma, foram identificados quais polígonos tiveram sua estrutura de ocupação alterada entre os anos do estudo (de 2009 a 2013) com a introdução da soja e os que não tiveram sua estrutura modificada.

3.3. Definição das variáveis de análise

Com o grid das unidades de análise definido, foi realizado um cruzamento espacial dessas unidades com diversas informações (variáveis de análise). Conforme sugerido pelos trabalhos já citados, três grandes grupos de variáveis foram considerados neste trabalho, sendo: variáveis agronômicas (relacionadas ao meio em que cada unidade de análise se encontra), logísticas (relativas à distância da unidade de análise em relação a elementos de suporte logístico) e econômicas (pertinentes ao potencial econômico de cada unidade produtiva).

As variáveis agronômicas consideradas neste trabalho foram: tipologia de solos, unidades climáticas e declividade. Além de terem sido citadas pelos autores estudados, essas variáveis têm influência direta sobre o potencial agrícola de uma área, pois tecnicamente, as condições de solo, relevo e clima podem variar de favoráveis a impeditivas para a instalação de uma produção agrícola.

As condições de solo podem impedir a mecanização, caso seja rochoso ou alagado, além de exigir diferentes níveis de correção química. Da mesma forma, o relevo influencia as condições de mecanização das áreas, podendo, se plano, facilitar as operações, se ondulado, dificultar as operações pelo excesso de manobras ou, se muito inclinado, impedir as operações mecanizadas. Já o clima pode impedir o desenvolvimento de culturas específicas ou limitar o seu uso ao longo do ano.

A base de dados dos solos de Mato Grosso foi extraída do trabalho desenvolvido por Moreira e Vasconcelos (2007). Como o sistema de classificação dos solos possui diversas classes, os autores sugeriram que os solos fossem agrupados seguindo padrões do limite do uso agrícola. Com isso, foi possível diminuir o volume de dados e facilitar a operação do *software* Arc Gis.

Como originalmente essa é uma variável qualitativa, seguindo a recomendação dos mesmos autores, as classes de solos foram agrupadas por critérios quantitativos indicando o seu potencial agrícola. Os solos com alto potencial agrícola receberam valor 1, os de médio potencial, valor 2, os de baixo potencial agrícola, valor 3, e os sem potencial agrícola, valor 4.

Os dados básicos referentes às unidades climáticas pertencentes a cada propriedade foram obtidos a partir do Atlas de Mato Grosso, organizado por Camargo

(2011). Foi extraído para cada uma das propriedades o valor médio das isoietas do acumulado de chuvas, o número médio de meses secos e a classificação média quanto à severidade climática. Dessas três variáveis, apenas a severidade climática, que originalmente era qualitativa, foi reclassificada quantitativamente pelos autores, tendo sido estabelecidos valores de 1 a 7; sendo que, quanto mais alto o valor, maior a severidade da seca.

A declividade dos solos foi calculada com base nas imagens do radar do projeto SRTM da Nasa, a partir das quais foram extraídas as curvas de nível, e através do *software* Arc Gis, foram calculadas as declividades em termos percentuais. Como o impacto da declividade sobre a mecanização não segue um padrão linear, os valores obtidos foram classificados conforme descrito a seguir: as declividades de 0% a 3% foram consideradas como relevo plano, recebendo o valor 1; de 3,01% a 6%, suave ondulado, com o valor 2; de 6,01% a 12%, ondulado, recebendo o valor 3; de 12,01% a 20%, fortemente ondulado, cujo valor foi 4; e acima de 20,01%, montanhoso ou escarpado, recebendo o valor 5.

De acordo com Aguiar, Câmara e Escada (2007); Jasinski et al. (2005) e Mann, Kaufmann et al. (2010) e comentado anteriormente, a conversão de áreas agrícolas também pode sofrer a influência de diversos fatores logísticos. Com base na experiência desses autores, os fatores logísticos selecionados para compor a análise deste trabalho foram: rodovias pavimentadas, rodovias não pavimentadas, silos e armazéns, sedes dos municípios de Mato Grosso, portos e terminais de exportação, jazidas de calcário, porto de origem dos fertilizantes e áreas de soja já em produção. O cálculo da menor distância de cada propriedade foi feito com base na distância mínima euclidiana do ponto central de cada unidade de análise até os elementos citados anteriormente.

A localização dos silos e armazéns foi cedida pela Conab (2015) e a localização da sede dos municípios foi extraída da base do IBGE (2015). A distância mínima euclidiana foi calculada pela linha reta formada entre o centroide do polígono da unidade de análise (propriedade) e as coordenadas geográficas do silo ou sede do município.

A localização dos portos e jazidas de calcário foi fornecida pelo Imea (2015). Nesse caso, buscando a maior precisão possível, não foi adotado o cálculo a partir de uma linha reta entre a propriedade e o porto, mas sim pela soma da distância em linha reta do centroide do polígono da unidade de análise (propriedade) até a sede do

município mais próximo e da distância por via rodoviária da sede do município até o porto mais próximo.

A base de dados de rodovias pavimentadas e não pavimentadas foi cedida pelo Imea (2015). Diferentemente dos demais fatores externos, cuja unidade básica de localização são as coordenadas geográficas ou centros de polígonos, por serem as estradas, linhas contínuas e frequentemente com grandes dimensões, foram gerados pontos a cada cinco quilômetros, permitindo o cálculo da distância do centro das propriedades até um desses pontos localizados sobre as estradas pavimentadas e não pavimentadas.

O último item de influência externa avaliado neste estudo foi a distância até outras áreas agrícolas. Nesse caso, foi calculada a distância entre as coordenadas do centroide de cada propriedade onde ocorreu a alteração do uso e ocupação do solo e as coordenadas do centroide da propriedade mais próxima onde houve a produção de soja no ano anterior.

Como indicado por Mann et al. (2010), as variáveis econômicas são importantes indicadores do potencial de conversão de uma área para a produção de soja. Como não existe um cadastro com os resultados contábeis de cada propriedade de Mato Grosso, foram estimados o custo operacional, a receita bruta e, por fim, a rentabilidade com a atividade de soja para cada polígono do grid de propriedades criado para Mato Grosso.

A rentabilidade é a diferença entre a receita bruta e os custos. Diversos fatores afetam tanto os custos como a receita, mas, para permitir a análise da rentabilidade, foi utilizado como base o custo operacional de produção de soja estimado pelo Imea (2015), que representa os gastos com insumos diretos para a produção mais os custos fixo e variável de máquinas e mão de obra utilizados diretamente na produção. A equação 1 indica o cálculo da rentabilidade operacional por hectare, que foi obtida pela diferença entre a receita bruta por hectare e o custo operacional por hectare. A composição das variáveis que compõem a rentabilidade deriva de uma série de indicadores, como será verificado nas equações 2, 3, 4, 5, 6, 7, 8 e 9.

$$Ro_{iy} = Rb_{iy} - Co_{iy} \quad (1)$$

(1) - Onde: Ro_{iy} é a rentabilidade em reais por hectare da propriedade i no ano y ; Rb_{iy} é a receita bruta em reais por hectare da propriedade i no ano y ; e Co_{iy} é o custo em reais por hectare da propriedade i no ano y .

$$Rb_{iy} = (Psp_y - (Dp_i \times Fp_y)) \times Pd \quad (2)$$

(2) – Onde: Rb_{iy} é a receita bruta em reais por hectare da propriedade i e ano y ; Psp_y é o preço da soja no porto em reais por tonelada para o ano y ; Dp_i é a distância em quilômetros da propriedade i até o porto; Fp_y é o preço do frete em reais por tonelada quilômetro útil (tku) para o ano y ; e finalmente Pd é a produtividade média em toneladas por hectare.

$$Co_{iy} = Is_{iy} + Om_{iy} \quad (3)$$

(3) - Onde: Co_{iy} é o custo operacional em reais por hectare da fazenda i no ano y ; Is_{iy} é o custo por hectare com insumos na propriedade i e ano y ; e Om_{iy} representa o custo com operações mecanizadas por hectare na propriedade i no ano y .

$$Is_{iy} = \left((Pfp_y + (Dp_i \times Fp_y)) \times f \right) + \left((Pcj_y + (Dj_i \times Fj_y)) \times c \right) + Pd_y \times d + Ps_y \times s \quad (4)$$

(4) – Onde: Is_{iy} é o preço dos insumos em reais por hectare da propriedade i e ano y ; Pfp_y é o preço do fertilizante no porto em reais por tonelada no ano y ; Dp_i é a distância em quilômetros da propriedade i até o porto; Fp_y é o preço do frete em reais por tonelada quilômetro útil (tku) no ano y ; f é a quantidade de fertilizante em toneladas por hectare utilizada; Pcj_y é o preço do calcário em reais por hectare na jazida no ano y ; Dj_i é a distância em quilômetros da propriedade i até a jazida de calcário; Fj_y é o frete em reais por tonelada quilômetro útil (tku) desde a jazida de calcário; c é a quantidade de calcário em toneladas por hectare; Pd_y é o preço dos defensivos em reais por litro no ano y ; d é a quantidade média de defensivos utilizada em litros por hectare; Ps_y é o preço da semente em reais por quilo no ano y e s é a quantidade de semente utilizada em quilos por hectare.

$$Om_{iy} = Cvm_{iy} + Cvi_i + Cfm_i + Cfl_{iy} \quad (5)$$

(5) – Onde: Om_{iy} representa o custo das operações mecanizadas em reais por hectare da propriedade i no ano y ; Cvm_{iy} é o custo variável com máquinas em reais por hectare na propriedade i e ano y ; Cvi_i é o custo variável com implementos em reais por hectare na propriedade i ; Cfm_i é o custo fixo com máquinas e implementos em reais por hectare na propriedade i ; e Cfl_{iy} é o custo fixo com mão de obra em reais por hectare da propriedade i no ano y .

$$Cvm_{iy} = \sum_{ji} \left(0,12Pt_j \times Prd_y + \frac{Vm_j \times Tm_j}{Uh_j} \right) \times Ro_j \quad (6)$$

(6) – Onde: Cvm_{iy} é o custo variável das máquinas em reais por hectare na propriedade i e ano y ; $0,12$ é a constante estabelecida por Conab (2010) para o consumo de diesel em litros por cavalo (cv); Pt_j é a potência, em cavalos (cv) da máquina j ; Prd_y é o preço do diesel em reais por litro no ano y ; Vm_j é o valor em reais de uma máquina j nova; Tm_j é a taxa de manutenção em percentual da máquina j ; Uh_j é o uso padrão em horas anual da máquina j ; e Ro_j é o uso esperado em horas por hectare da máquina j .

$$Cvi_i = \sum_{ji} \left(\frac{Vi_j \times Ti_j \times Ro_j}{Uh_j} \right) \quad (7)$$

(7) – Onde: Cvi_i é o custo variável dos implementos em reais por hectare na propriedade i ; Vi_j é o valor em reais do implemento j novo; Ti_j é a taxa de manutenção em percentual do implemento j ; Ro_j é a utilização em horas por hectare do implemento j ; e Uh_j é a utilização padrão anual em horas do implemento j .

$$Cfmi_i = \sum_{ji} \left\{ \frac{\left(\frac{Vmi_j - Vmi_j \times Td_j}{Ua_j} \right) + \left[\left(\frac{Vmi_j - Vmi_j \times Td_j}{2} \right) \times Ts_j \right]}{Ao_i} \right\} \quad (8)$$

(8) – Onde: $Cfmi_i$ é o custo fixo das máquinas e implementos em reais por hectare da propriedade i ; Vmi_j é o valor em reais das máquinas ou implementos j ; Td_j é a taxa percentual de sucata da máquina ou implemento j ; Ua_j é o número de anos de uso da máquina ou implemento j ; Ts_j é a taxa de seguro padrão em percentual para a máquina ou implemento j ; e Ao_i é a área em hectares da propriedade i .

$$Cfli_y = \sum_j^i \left(\frac{Sl_{jy}}{Ao_i} \right) \quad (9)$$

(9) – Onde: $Cfli_y$ é o custo fixo em reais por hectare com a mão de obra da propriedade i no ano y , Sl_{jy} representa o salário em reais do funcionário j no ano y ; e Ao_i representa a área em hectares da propriedade i .

Para o cálculo dos impactos do frete sobre os fertilizantes, foram consideradas a distância em linha reta do centro da propriedade até a sede do município mais próximo e a distância da sede deste município até o porto de Santos, por onde desembarca a maior parte desses produtos. Com os dados de preço dos fertilizantes e custo do frete por tonelada quilômetro útil (tku) fornecidos pelo Imea (2015), foi estimado o preço pago por cada unidade produtiva entregue em cada fazenda (unidade fundiária).

O raciocínio para o custo do calcário posto na fazenda foi o mesmo; porém nesse caso, foram utilizadas várias origens possíveis, já que Mato Grosso tem diversas jazidas desse insumo. Obviamente, foi tomado como válido, o custo mais baixo que, geralmente, é oferecido pela jazida mais próxima.

Para definir os critérios técnicos de utilização mínima e máxima de área por máquinas, implementos e mão de obra, foi realizado um painel com especialistas do Instituto Mato-Grossense de Economia Agropecuária.

3.4. Modelagem da mudança do uso e ocupação dos solos

No presente trabalho, foram utilizados três diferentes métodos de seleção de modelos. O primeiro foi o método estatístico empregando a técnica de Análise de Componentes Principais (ACP). Em seguida, modelos definidos empiricamente pela

natureza dos dados. A última metodologia de definição de modelo foi por painel de especialistas.

Para a seleção das variáveis resposta foi utilizada a metodologia de Análise de Componentes Principais (ACP), cujas propriedades características foram descritas na subseção 2.5. Com um banco de dados com 38 variáveis e mais de 6 mil observações, o uso de uma ferramenta para o cálculo computacional torna-se fundamental, uma vez que se espera uma base de dados muito grande; por essa razão, foram utilizados o *software* R e o pacote estatístico *FactoMineR*.

Foram utilizadas para a análise, apenas as unidades produtivas onde ocorreu incremento da área de lavoura de soja entre anos consecutivos. Para evitar distorções numéricas, os dados foram reescalados em valores entre 0 e 1 com o auxílio do pacote *Vegan*, também para o *software* R. Além disso, o peso de cada unidade produtiva foi ponderado pela área de incremento de lavoura de soja em cada unidade.

Para a construção dos modelos foram considerados apenas os componentes com uma ou mais variáveis com pesos (w) maior que $|0,7|$. Também foi construído um modelo considerando todas as variáveis com peso maior que $|0,7|$, independentemente dos componentes.

Buscando entender o impacto isolado de cada tipo de variável na previsão da conversão de áreas de soja, as variáveis foram agrupadas em quatro blocos, de acordo com a natureza de cada uma, sendo: bloco com variáveis econômicas, bloco com variáveis agronômicas ou ambientais, bloco com variáveis de logística geral e bloco com variáveis de influência da vizinhança.

Para contrastar com o modelo selecionado automaticamente por estatística, foi realizado um painel com um grupo de cinco especialistas do Instituto Mato-Grossense de Economia Agropecuária. Esse grupo de especialistas deve ter, preferencialmente, características multidisciplinares com atuação profissional distinta buscando o contraste das visões. A metodologia de painel consiste em conduzir uma reunião entre os especialistas selecionados, para que se estabeleça por consenso, a escolha empírica das variáveis que mais contribuíram com o processo em questão, no caso, a conversão de áreas de pastagem ou outro uso para a produção de soja.

3.5. Análise estatística dos modelos

Para avaliar a probabilidade de conversão do uso e ocupação dos solos, foi utilizada a regressão Logit, que permite avaliar a probabilidade de se obter ou não

uma mudança. Como é utilizada uma variável binária como base para a construção do modelo de regressão, é possível determinar qual a probabilidade da passagem da situação 0, neste caso, “sem lavoura”, para a situação 1, “com lavoura”. A equação 16 demonstra o método de cálculo da probabilidade de cada propriedade.

$$Y_i = \frac{1}{1 + \exp\{\sum_{j=0}^n \beta_j X_{ij}\}} + e_i \quad (16)$$

(16) - Onde: Y_i é a probabilidade de conversão para área de soja de uma propriedade i ; β_j é o coeficiente de multiplicação da variável j ; X_{ij} representa o valor da variável j para a propriedade i ; e e_i representa o erro de cálculo da função para a propriedade i .

Para a estimativa dos parâmetros de cada variável (β_j) no modelo de regressão Logit foi usado o *software* R. Para a exclusão de variáveis não significativas (com p-valor acima de 0,05), como primeiro passo foi utilizada a ferramenta *Step Back*, que exclui os modelos com menor AIC. No segundo passo, foram excluídas manualmente as variáveis não significativas.

Para realizar os testes estatísticos pertinentes foi utilizado o *software* R, tendo sido aplicado o teste de normalidade pela metodologia de Komogolov-Smirnov, valendo-se da ferramenta *ks.test*. Já para o teste de diferença pareada das médias foi utilizado o teste de Mann-Whitney-Wilcoxon (*wilcox.test*) e para o teste de diferenças múltiplas para dados não paramétricos foi utilizado o pacote *nparcomp*.

Para comparação entre as previsões de cada modelo foi utilizada a metodologia da curva *Roc* (do inglês: *Receiver Operating Characteristic*), indicando estatisticamente qual modelo foi mais correto para o período em questão. Segundo Prati et al. (2008), essa ferramenta é utilizada na área econômica para avaliar a qualidade de predição de eventos raros. Nas áreas de mineração de dados e aprendizagem de computacional também tem sido utilizada para a avaliação de modelos de classificação.

O gráfico *Roc* contém dois eixos, o eixo X representa o percentual de falsos positivos e o eixo Y representa o percentual de verdadeiros positivos. Assim, os dados positivos (onde ocorreram as conversões) são ordenados e classificados. Quanto mais a curva *Roc* se aproximar do ponto (0%,100%), melhor é a sua capacidade preditiva; e quanto mais próximo da linha diagonal é o gráfico, mais aleatório é o processo.

4. ESTUDO DE CASO

O estudo de caso foi dividido em 4 subseções, buscando trazer os resultados completos da pesquisa. Na primeira subseção do estudo de caso foi apresentado o mapeamento básico gerado neste trabalho. Na subseção 4.2, foi avaliado como foi a evolução do uso e ocupação dos solos entre 2008 e 2013. Na subseção 4.3, foi analisado o comportamento das variáveis. Na subseção 4.4, foram avaliados os resultados do processo de modelagem do uso e ocupação dos solos. Finalmente, na subseção 4.5 foi realizada a análise estatística dos modelos.

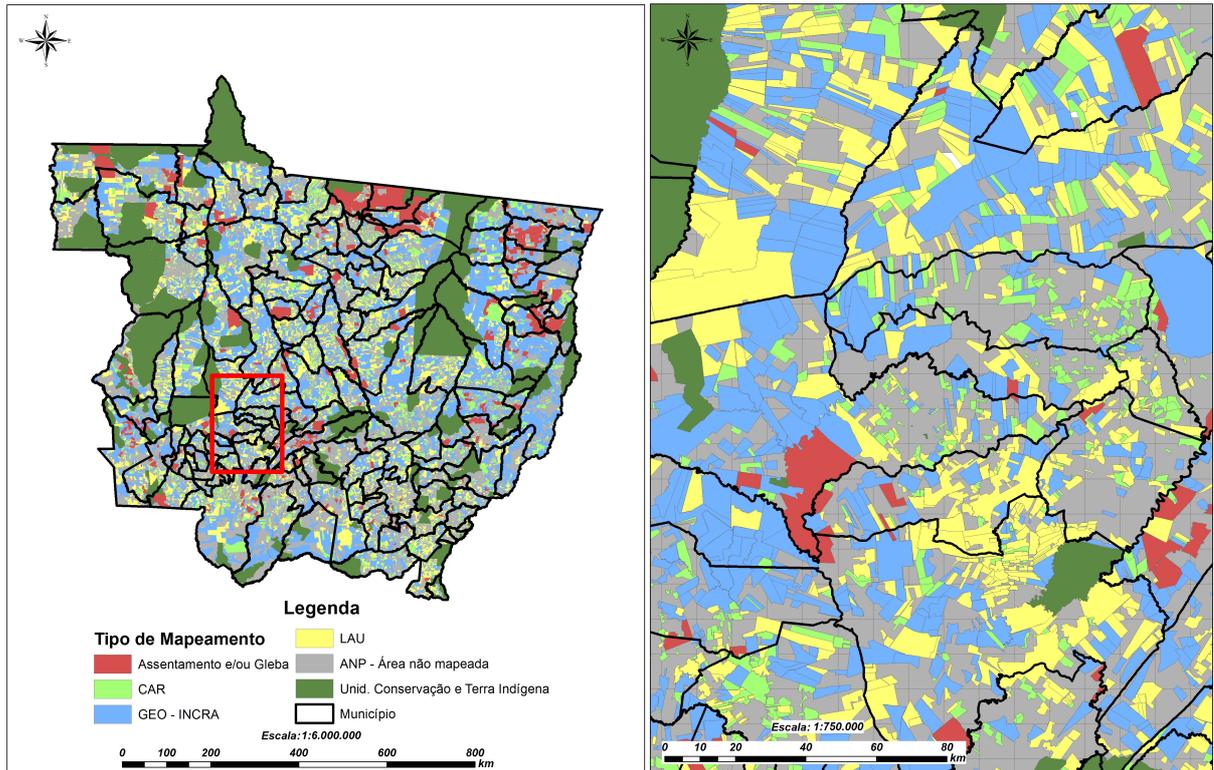
4.1. Resultados do processo de mapeamento do uso e ocupação dos solos

A Figura 3 ilustra o mosaico de propriedades criado para o levantamento dos dados e sua análise, criado a partir do perímetro das propriedades com georreferenciamento (GEO), licença ambiental única (LAU) ou cadastro ambiental rural (CAR) e por fim a divisão de áreas não mapeadas (ANP) que, como explicado na subseção 3.2, foram divididas em polígonos de tamanhos máximos de 10 mil hectares. Como o campo de análise deste estudo foi a área com potencial de produção agrícola do Estado de Mato Grosso, as áreas de terras indígenas, de unidades de conservação e de assentamentos rurais não foram consideradas.

Ao todo, foram analisadas as informações de 38.393 propriedades, cujas áreas somam 66,008 milhões de hectares, representando 73,2% da área total de Mato Grosso. A *Tabela 2* indica a distribuição do número de propriedades e a respectiva área acumulada, em função da camada analisada.

Vale destacar que, apesar de 73,2% da área total de Mato Grosso ter sido considerada como passível de exploração pelo setor privado, boa parte dessa área ainda possui a sua vegetação original (Floresta Amazônica, Cerrado ou Pantanal), conforme percentual de preservação estabelecido pelo Código Florestal, de acordo com o bioma de localização.

Figura 3 - Grid de unidades fundiárias mínimas e recorte com exemplo



Fonte: Elaborado pelo autor

Tabela 2 - Total de unidades mínimas de análise (propriedades) por camada

| | Número de propriedades | % | Área em hectares das unidades fundiárias | % |
|--------------|-------------------------------|------------|---|------------|
| GEO | 9.046 | 23,6 | 22.609.611 | 34,3 |
| LAU | 7.718 | 20,1 | 11.240.423 | 17,0 |
| CAR | 9.341 | 24,3 | 6.499.357 | 9,8 |
| ANP | 12.293 | 32,0 | 25.659.323 | 38,9 |
| Total | 38.398 | 100 | 66.008.714 | 100 |

Fonte: Elaborado pelo autor

A área constituída por unidades produtivas reais (GEO, LAU e CAR) representa 44,8% da área total do Estado de Mato Grosso e 61,1% da área analisada neste estudo. Em relação ao total de unidades fundiárias analisadas, 26.105 (68%) eram propriedades reais (com GEO, LAU ou CAR) e o restante propriedades fictícias, ou seja, criadas sobre as áreas não mapeadas (ANP), com tamanho máximo estabelecido de 10 mil hectares.

4.2. Evolução do uso e ocupação dos solos de Mato Grosso

Em relação à área convertida para soja, os valores foram positivos em todos os anos (Figura 4), saindo de 250 mil hectares, em 2009, para o valor máximo de 368 mil hectares, em 2012 (Tabela 3). O número de propriedades convertidas também variou, sendo o máximo de 1817 propriedades convertidas, em 2013, e o mínimo de 1045 propriedades, em 2009, quando comparado ao ano anterior. Da mesma forma, o valor médio de área convertida para soja em cada propriedade variou de 186 hectares, em 2013, para 277 hectares, em 2012.

Embora as áreas não mapeadas (ANP) tenham representado 40% de todo o grid de propriedades, apenas 25% da expansão da soja ocorreu nesses locais. Em outras palavras, 75% da expansão da soja ocorreu em áreas mapeadas pelo CAR, GEO e/ou LAU.

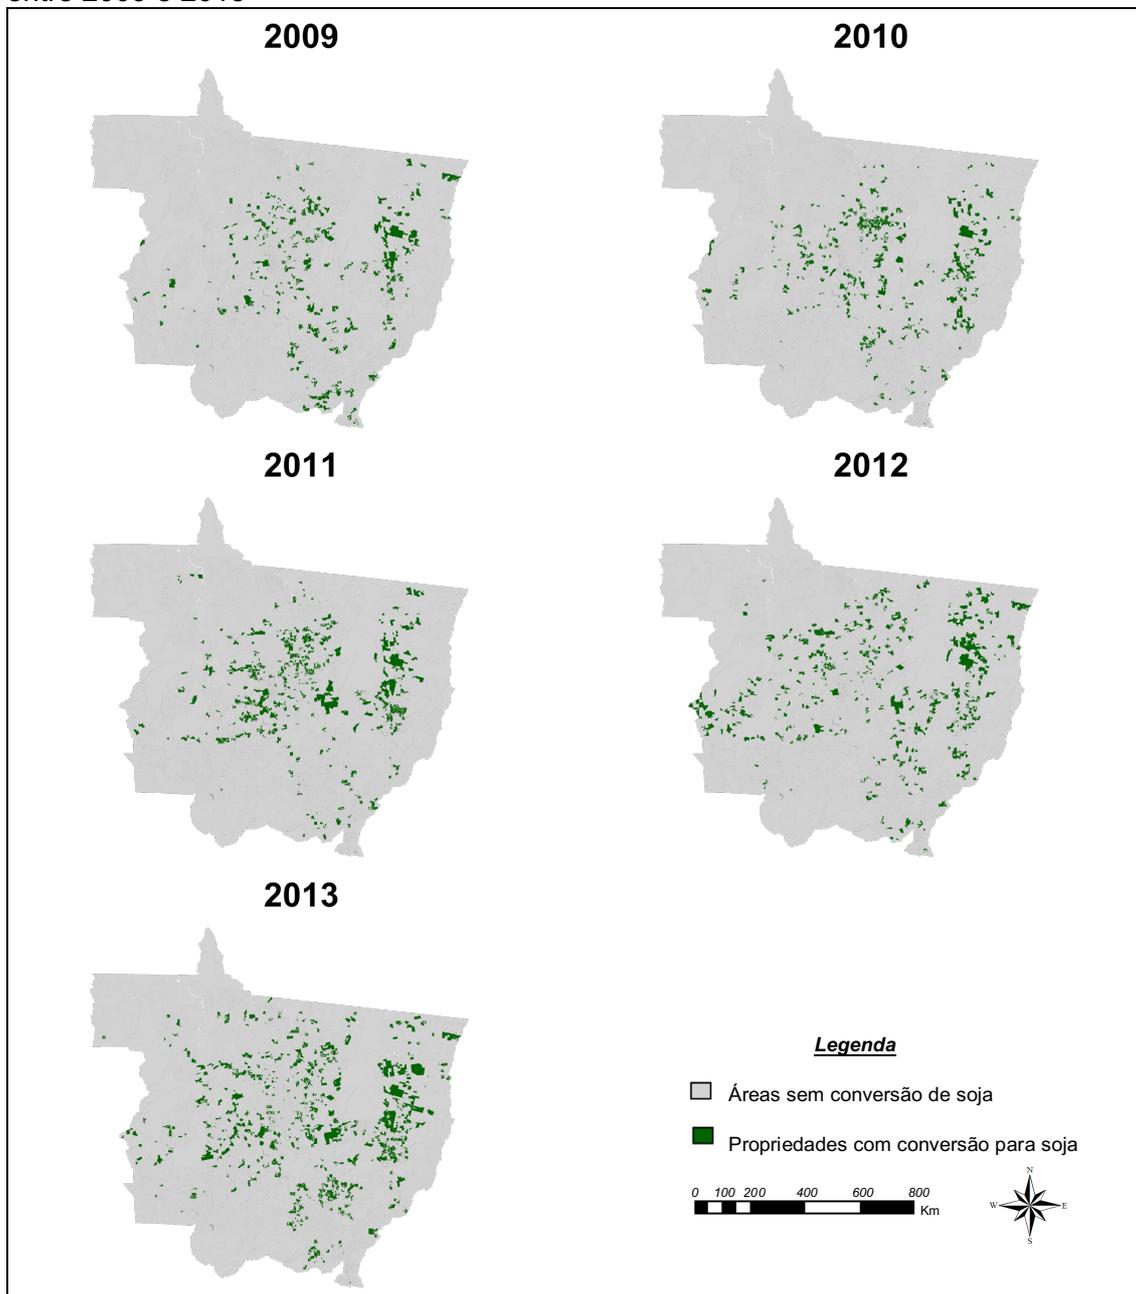
Embora 2012 tenha sido o ano com a maior expansão da produção de soja, também foi o ano com o menor crescimento proporcional sobre áreas de remanescentes florestais (3,4%). A maior parte desse crescimento (87,7%) se deu sobre áreas de pastagens (calculados a partir da Tabela 3). A maior proporção de expansão da soja sobre as áreas florestais foi observada em 2013 (7,8%), quando a expansão sobre pastagens e outras classes de cobertura do solo representaram 77,6% e 14,6%, respectivamente.

Tabela 3 - Estatísticas da conversão das áreas para soja entre 2009 e 2013

| Ano | Número de propriedades onde houve conversão | Área total convertida (ha) | Área média convertida por propriedade (ha) | Percentual de propriedades que não possuíam soja no ano anterior de conversão |
|------|---|----------------------------|--|---|
| 2009 | 1.045 | 250.660 | 240 | 22 |
| 2010 | 1.080 | 271.121 | 251 | 20 |
| 2011 | 1.270 | 270.701 | 213 | 20 |
| 2012 | 1.331 | 368.732 | 277 | 43 |
| 2013 | 1.817 | 338.420 | 186 | 27 |

Fonte: Elaborado pelo autor

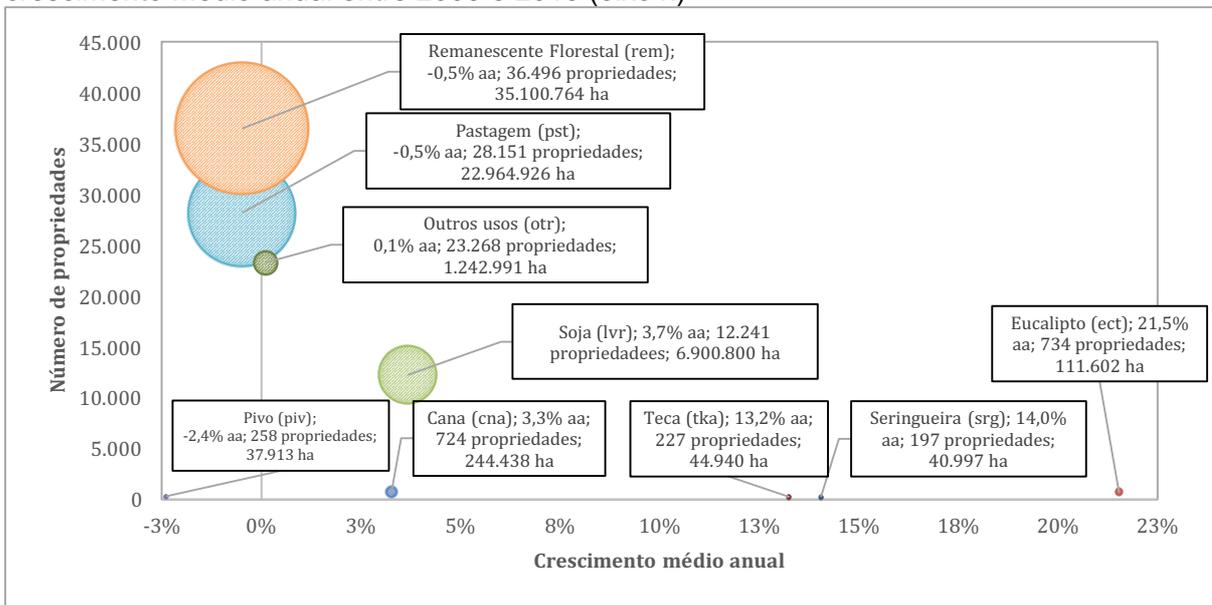
Figura 4 - Destaque das propriedades agrícolas onde ocorreu a ampliação das áreas de soja entre 2009 e 2013



Fonte: Elaborado pelo autor

No que tange ao tipo de cobertura do uso e ocupação dos solos, a Figura 5 resume as características gerais do histórico do crescimento entre 2008 e 2013 (eixo X), do número de propriedades (eixo y) e da área ocupada por cada categoria (tamanho da bolha) em 2013.

Figura 5 - Gráfico do uso e ocupação dos solos de Mato Grosso, representando a área total ocupada (tamanho da bolha) e o número de propriedades (eixo y), em 2013, e o crescimento médio anual entre 2008 e 2013 (eixo x)



Fonte: Elaborado pelo autor

Dentre as nove ocupações mapeadas, apenas três tiveram redução da área na média das variações anuais entre 2008 e 2013: área de pivô (piv), pastagem (pst) e remanescente florestal (rem). Apesar da redução observada, o remanescente florestal é a cobertura mais abundante do Estado, representando 53% das áreas das propriedades agrícolas, estando presente em 95% delas. A pastagem é o segundo tipo de ocupação mais disseminado, estando presente em mais de 28 mil propriedades, ou 73% do total, representando quase 23 milhões de hectares, ou 34% da área total.

Considerando os usos que tiveram incremento nesse período, o maior crescimento médio anual foi observado para o eucalipto (ect), que cresceu em média 21,5% ao ano, entre 2008 e 2013, mas é encontrado em apenas 2% das propriedades com uma área total de 111 mil hectares, ou 0,2% do total; situações semelhantes são observadas com as culturas florestais seringueira (srg) e teka (tka).

Apesar de não figurar entre as ocupações que tiveram os maiores crescimentos médios anuais, a ocupação dos solos com lavoura de soja (lvr) foi a que teve o maior crescimento em termos absolutos, vindo a ocupar quase 7 milhões de hectares, ou 10,3% do total, e com presença em mais de 12 mil propriedades, ou 32% do total.

A área de cana (cna) teve crescimento médio anual de 3,3%, mas ainda está restrita a um limitado grupo de propriedades (2% do total), representando menos de 1% da área ocupada das propriedades. A área com outros usos (otr) permaneceu

praticamente estável, mas ainda assim, representa mais de 1,2 milhão de hectares, ou 2% do total, com presença em 60% das propriedades.

4.3. Análise das variáveis

A Tabela 4 evidencia a distribuição das características naturais das propriedades, considerando declividade, acumulado médio de chuvas, número médio de meses secos, severidade da seca, e aptidão dos solos.

Tabela 4 - Distribuição por decil das condicionantes ambientais das propriedades do Estado de Mato Grosso

| Decil | Declividade e - dcv (%) | Chuva média anual – chm (mm) | Número médio de meses secos por ano - msc | Classificação quanto à severidade da seca - svd ¹ | Classificação do solo quanto à aptidão agrícola - csl ² |
|-------|-------------------------|------------------------------|---|--|--|
| 0% | 1,0% | 1200 | 2 | 1 | 1 |
| 10% | 1,9% | 1450 | 4 | 2 | 1 |
| 20% | 2,6% | 1550 | 4 | 3 | 1 |
| 30% | 3,1% | 1700 | 5 | 3 | 1 |
| 40% | 3,5% | 1800 | 5 | 4 | 1,3 |
| 50% | 3,8% | 1900 | 5 | 4 | 2 |
| 60% | 4,2% | 1950 | 5 | 4 | 2 |
| 70% | 4,8% | 2050 | 5 | 4 | 2,2 |
| 80% | 5,9% | 2050 | 5 | 5 | 2,9 |
| 90% | 7,9% | 2150 | 6 | 5 | 3 |
| 100% | 21,8% | 2300 | 8 | 7 | 4 |

¹(1 baixo - 7 forte)

²(1 muito favorável, 2 moderadamente favorável, 3 pouco favorável, 4 desfavorável)

Fonte: Elaborado pelo autor

A declividade do Estado é predominantemente plana, sendo que pouco mais de 20% das propriedades apresentam declividade média acima de 6%, ou seja, caracterizada como de ondulada à montanhosa. Essa característica seguramente condiciona a maior parte das propriedades como passíveis de mecanização no quesito topografia.

O regime hídrico também é extremamente favorável à produção agrícola, com cerca de 10% das propriedades com acumulado médio anual de chuvas abaixo de 1450 milímetros e mais de 8 meses secos por ano. Na região do Pantanal predominam essas características, mas, apesar do relevo plano, a baixa permeabilidade de água

faz com que, mesmo chovendo menos do que a média do Estado, haja ali um acúmulo de água, inviabilizando qualquer possibilidade de produção agrícola.

A severidade da seca na maioria do Estado é de média a elevada. No entanto, como está concentrada em poucos meses do ano, essa característica não traz grandes prejuízos para as culturas tradicionalmente produzidas no período de entressafra (milho e algodão); sendo inclusive, benéfica, devido à menor ocorrência de pragas e doenças e permitindo a secagem dos produtos ainda no campo.

Por fim, apenas cerca de 10% das propriedades têm classificação média de solos desfavoráveis à produção agrícola e pelo menos 60% têm condições médias de tipologia de solos favoráveis ou moderadamente favoráveis para a produção agrícola, indicando que os solos do Estado de Mato Grosso são pouco restritivos à expansão agrícola.

As escalas das operações agrícolas foram definidas através de painéis realizados com os especialistas do Instituto Mato-Grossense de Economia Agropecuária (Imea). Nesse processo, foram determinadas empiricamente as áreas mínimas que cada propriedade deve ter para poder adquirir uma máquina ou contratar um funcionário e, também, a área máxima que uma máquina ou trabalhador é capaz de atender, sendo que acima desses valores, serão necessários uma nova aquisição ou contratação.

No caso das propriedades cujas áreas não atingiram o valor considerado como mínimo para a aquisição de uma das máquinas ou implementos listados, o custo estimado de arrendamento desses equipamentos já com operadores, foi considerado como sendo o dobro do custo por hectare de uma dessas máquinas em uso ótimo. Como exemplo, na Tabela 5 a seguir, é possível verificar os indicadores de formação do custo das máquinas agrícolas, bem como a escala mínima considerada para cada máquina.

As informações definidas pelos especialistas foram área mínima (ha), área máxima (ha) e uso por hectare (h/ha) que cada máquina consegue operar em uma safra. Por terem um preço de compra menor, os tratores pequenos e médios e as colhedoras de 30 pés foram considerados como os de menor área mínima; sendo que produtores com esse tamanho de área (300 ha), geralmente, já têm esse padrão de máquina.

Já tratores grandes foram considerados como sendo viáveis para uma área agrícola maior, tendo em vista que aqueles que não têm pelo menos 600 hectares,

geralmente não têm esse tipo de máquina. O mesmo ocorre com o autopropelido que, geralmente, é substituído pelo pulverizador de arrasto em propriedades com área abaixo de 1000 hectares, sendo necessária a aquisição de um novo autopropelido a cada 2000 hectares de área de uso.

Tabela 5 - Parâmetros utilizados para cálculo do custo das máquinas agrícolas de cada propriedade

| Máquina | Unidade | Trator Pequeno | Trator Médio | Trator Grande | Auto Propelido | Colhedora 30 pés |
|------------------|---------|----------------|--------------|---------------|----------------|------------------|
| Potência | Cv | 85 | 106 | 180 | 130 | 240 |
| Preço | Mil R\$ | 198 | 305 | 365 | 610 | 1.010 |
| Vida útil | h | 10000 | 10000 | 10000 | 10000 | 5000 |
| Utilização anual | h/ano | 1000 | 1000 | 1000 | 1000 | 500 |
| Taxa residual | % | 30% | 30% | 30% | 30% | 30% |
| Taxa seguro | % | 1,2% | 1,2% | 1,2% | 1,2% | 1,2% |
| Taxa manutenção | % | 40,0% | 40,0% | 40,0% | 40,0% | 25,0% |
| Área mínima | ha | 300 | 300 | 600 | 1000 | 300 |
| Área máxima | ha | 1000 | 1000 | 1500 | 2000 | 900 |
| Uso por hectare | h/ha | 0,35 | 0,50 | 0,13 | 0,28 | 0,20 |

Fonte: Elaborado pelo autor

Seguindo a mesma lógica, na Tabela 6 e Tabela 7 é possível verificar os indicadores definidos para os implementos agrícolas e para a mão de obra. No caso dos implementos, foi estabelecido um valor padrão de área mínima de 300 hectares e área máxima de 1000 hectares.

Tabela 6 - Parâmetros utilizados para calcular o custo com implementos em cada fazenda

| Implemento | Unidade | Carreta agrícola | Carreta canudo | Concha dianteira | Distribuidor de calcário | Grade aradora | Grade niveladora | Guincho | Plantadora de 15 linhas | Tanque de água |
|------------------|---------|------------------|----------------|------------------|--------------------------|---------------|------------------|---------|-------------------------|----------------|
| Preço | mil R\$ | 4,50 | 45,00 | 22,00 | 30,00 | 22,00 | 20,00 | 11,10 | 125,00 | 8,50 |
| Vida útil | h | 2500 | 2500 | 10000 | 2500 | 2000 | 2000 | 10000 | 3000 | 3000 |
| Uso anual | h/ano | 250 | 250 | 1.000 | 250 | 200 | 200 | 1.000 | 300 | 300 |
| Valor residual | % | 20% | 20% | 10% | 20% | 10% | 10% | 10% | 25% | 25% |
| Custo com seguro | % | 0,6% | 0,6% | 0,6% | 0,6% | 0,6% | 0,6% | 0,6% | 0,6% | 0,6% |
| Custo manutenção | % | 40% | 40% | 100% | 60% | 70% | 70% | 70% | 80% | 80% |
| Área mínima | ha | 300 | 300 | 300 | 300 | 300 | 300 | 300 | 300 | 300 |
| Área máxima | ha | 1000 | 1000 | 1000 | 1000 | 1000 | 1000 | 1000 | 1000 | 1000 |

Fonte: Elaborado pelo autor

No caso da mão de obra (Tabela 7), os operadores de trator passam a ser contratados a partir de 300 hectares; porém, o operador dos tratores grandes pode operar até o dobro da área do trator médio. Já o operador do autopropelido é contratado em áreas de produção superiores a 1000 hectares e um novo trabalhador deve ser contratado a cada 2000 hectares. O ajudante geralmente é contratado para áreas pequenas, acima de 50 hectares, mas um novo só precisa ser contratado no caso de áreas acima de 1500 hectares.

Tabela 7 - Parâmetros utilizados para cálculo do custo com mão de obra em cada fazenda

| Equipe | Unidade | Operador de trator grande | Operador de trator médio e pequeno | Operador de autopropelido | Ajudante |
|---------------------------|---------|---------------------------|------------------------------------|---------------------------|-----------|
| Salário Mensal | R\$ | 3.000,00 | 3.000,00 | 3.000,00 | 1.500,00 |
| Salário Anual | R\$ | 53.986,50 | 53.986,50 | 53.986,50 | 26.993,25 |
| Área mínima por empregado | ha | 300 | 300 | 1000 | 50 |
| Área máxima por empregado | ha | 1500 | 750 | 2000 | 1500 |

Fonte: Elaborado pelo autor

No modelo geral, a escala de produção interferiu diretamente nos custos fixos operacionais da produção. Isso porque áreas pequenas dificilmente permitem o uso ótimo dos recursos máquina e mão de obra, gerando ociosidade e, conseqüentemente, maiores custos com depreciação e seguro.

A logística também interferiu diretamente nos custos e na receita do modelo. Em relação aos custos, foi considerado o efeito da localização da propriedade apenas no preço dos fertilizantes e do calcário. Como são utilizados em grandes volumes e seu valor agregado é relativamente baixo, a influência do custo do transporte sobre os custos desses insumos passa a ser grande.

A localização da propriedade impacta diretamente na receita final obtida com a produção de soja; isso porque o valor pago pelo produto é formado com base no mercado internacional, tomando-se como referência, a cidade de Chicago, nos EUA. Calcula-se, então, o chamado preço de paridade, que permite saber o preço com que essa *commodity* desembarca em cada porto do Brasil. Excluindo-se desse valor, o custo do frete até os referidos portos, tem-se o valor líquido recebido pela soja. Neste estudo, foi adotado como base o porto mais próximo, por exercer menor impacto sobre

os preços finais.

Além da escala impactar a rentabilidade – já que o aumento da área reduz o custo fixo das máquinas, implementos e mão de obra – o preço dos insumos e o valor da soja também influenciaram o resultado e, conseqüentemente, a área média estimada para cada faixa de retorno.

Na Tabela 8, fica claro que o ano de 2010 foi o de pior rentabilidade operacional teórica da soja, exigindo-se uma área proporcionalmente maior para se obter uma margem mais elevada de rentabilidade operacional. O ano de melhor rentabilidade operacional foi o de 2012, que permitiu margem operacional teórica de até 200% para propriedades com mais de 4500 hectares de área útil.

Tabela 8 - Tamanho médio das propriedades por ano e faixa de rentabilidade operacional teórica

| Faixa de rentabilidade operacional | Área média (ha) para cada ano | | | | | |
|------------------------------------|-------------------------------|------|------|------|------|------|
| | 2008 | 2009 | 2010 | 2011 | 2012 | 2013 |
| 0% - 20% | 176 | 184 | 193 | 178 | 201 | 205 |
| 20% - 40% | 192 | 492 | 910 | 194 | 185 | 166 |
| 40% - 60% | 261 | 2291 | 2720 | 300 | 159 | 175 |
| 60% - 80% | 1106 | 3956 | 4008 | 1255 | 190 | 208 |
| 80% - 100% | 2692 | 4531 | 4558 | 2899 | 188 | 667 |
| 100% - 120% | 4133 | | | 4083 | 571 | 1931 |
| 120% - 140% | 4689 | | | 4535 | 1503 | 3455 |
| 140% - 160% | | | | | 3046 | 4021 |
| 160% - 180% | | | | | 4224 | 4802 |
| 180% - 200% | | | | | 4521 | |

Fonte: Elaborado pelo autor

As condicionantes logísticas das propriedades também compõem um importante aspecto de influência do uso e ocupação dos solos de uma região. A Tabela 9 representa a distribuição geral dessas condicionantes, considerando a distância de áreas agrícolas, de estradas pavimentadas e de não pavimentadas, de municípios, de armazéns, de portos e de jazidas de calcário, bem como o tamanho das áreas agrícolas, a quantidade de armazéns e a capacidade de armazenagem em determinados raios de distância.

Uma característica atual da logística de entorno das propriedades é que mais de 75% delas está a menos de 25 quilômetros, a partir do seu centro, de outra área

agrícola, ou seja, a uma curta distância. A consequência disso é que cerca da metade das propriedades tem uma área significativamente alta (mais de 74,5 mil hectares) de produção agrícola no raio de 50 quilômetros de distância.

Tabela 9 - Distribuição estatística das variáveis logísticas das propriedades de Mato Grosso em 2013

| | Mínimo | 1° Quartil | Mediana | 3° Quartil | Máximo |
|---|--------|------------|-----------|------------|------------|
| Distância mínima até área agrícola - dmia (km) | 0,0 | 2,8 | 8,3 | 23,3 | 211,4 |
| Área agrícola a até 50 km - ra050 (ha) | 0 | 4.285 | 74.572 | 262.629 | 844.335 |
| Área agrícola a até 100 km - ra100 (ha) | 0 | 104.557 | 430.211 | 896.002 | 2.290.419 |
| Área agrícola a até 200 km - ra200 (ha) | 0 | 1.104.581 | 1.796.150 | 2.857.826 | 4.097.190 |
| Distância mínima até estrada não pavimentada - denmi (km) | 0,0 | 4,7 | 10,6 | 19,8 | 127,2 |
| Distância mínima até estrada pavimentada - depmi (km) | 0,0 | 8,7 | 21,7 | 48,7 | 402,8 |
| Distância mínima até sede de municípios - dsmmi (km) | 0,2 | 19,1 | 31,6 | 48,1 | 225,4 |
| Distância mínima até porto - dpmi (km) | 440 | 1.115 | 1.220 | 1.402 | 1.702 |
| Distância mínima até porto de Santos - dpf (km) | 1.114 | 1.695 | 1.983 | 2.189 | 2.874 |
| Distância mínima até jazida de calcário - djc (km) | 1 | 139 | 276 | 518 | 1.072 |
| Distância mínima até armazém - dami (km) | 0,1 | 8,5 | 18,3 | 38,1 | 414,2 |
| Capacidade de armazenamento a até 25 km - srv025 (t) | 0 | 0 | 12.443 | 112.730 | 2.023.040 |
| Capacidade de armazenamento a até 50 km - srv050 (t) | 0 | 10.750 | 106.452 | 544.281 | 4.012.002 |
| Capacidade de armazenamento a até 100 km - srv100 (t) | 0 | 83.076 | 689.858 | 2.361.692 | 8.013.937 |
| Capacidade de armazenamento a até 200 km - srv200 (t) | 0 | 1.220.727 | 4.035.896 | 7.099.568 | 14.404.253 |
| Número de armazéns a até 25 km - srq025 (unidades) | 0 | 0 | 2 | 10 | 105 |
| Número de armazéns a até 50 km - srq050 (unidades) | 0 | 1 | 9 | 43 | 216 |
| Número de armazéns a até 100 km - srq100 (unidades) | 0 | 10 | 53 | 182 | 482 |
| Número de armazéns a até 200 km - srq200 (unidades) | 0 | 93 | 315 | 583 | 934 |

Fonte: Elaborado pelo autor

Quando considerados maiores raios de distância, a presença da produção agrícola se torna ainda mais evidente. Considerando-se um raio de 100 quilômetros, mais da metade das propriedades do Estado tem no seu entorno uma área de soja igual ou superior a 430 mil hectares e 1.796 mil hectares, quando se considera um raio de 200 quilômetros; valores que superam a área de produção agrícola de soja da maioria dos estados brasileiros.

Quanto ao acesso a estradas, parâmetro apontado como crítico em Mato Grosso, mais de 75% das propriedades estão a uma distância de no máximo 20 quilômetros de uma via não pavimentada. Considerando as vias pavimentadas, a situação é mais crítica, pois mais da metade está a distâncias superiores a 20

quilômetros, chegando-se ao nível crítico máximo, com propriedades localizadas a mais de 400 quilômetros de uma via pavimentada e 120 quilômetros de uma via não pavimentada.

A grande extensão territorial aliada ao baixo número de municípios (141, (IBGE, 2015)) leva a grandes distâncias entre as propriedades e as sedes municipais e, conseqüentemente, aos serviços públicos básicos. Quase 25% do total das propriedades está a uma distância em linha reta superior a 50 quilômetros das sedes dos municípios, podendo chegar a até 225 quilômetros.

Como Mato Grosso está no centro do continente sul-americano, existem diversas opções de portos para a exportação dos produtos agropecuários, mas as distâncias são elevadas. Na Tabela 9 fica evidenciado que, considerando-se todas as opções de portos para escoamento, a menor distância até um porto (dpmi) seria de 440 quilômetros, referente à distância das propriedades localizadas na região Oeste de Mato Grosso até a cidade de Porto Velho, em Rondônia, onde os produtos são colocados em barcaças para serem transbordados para navios posteriormente. Já a distância máxima até o porto mais próximo, considerando-se qualquer um dos portos, seria de pouco mais de 1700 quilômetros.

No entanto, considerando-se apenas o porto de Santos (dpf), que é a referência na formação de preços dos grãos no Brasil, pois é por onde a maioria dos grãos é embarcada e por onde entra a maior parte dos insumos agrícolas, a distância mínima constatada seria de 1.114 quilômetros, podendo chegar a até 2.874 quilômetros, mais de mil quilômetros a mais de quando são consideradas todas as alternativas, evidenciando a importância da expansão das possibilidades de escoamento, como apontado pelo estudo realizado por Macrologística (2013).

Em relação à distância das jazidas de calcário – insumo básico para a produção agrícola, já que a maioria absoluta dos solos de Mato Grosso tem pH ácido e precisa da chamada calagem para produzir grãos – mais da metade das propriedades estão a uma distância superior a 250 quilômetros, situação crítica, já que nessas condições, o custo do frete até as propriedades pode superar o custo do próprio calcário; havendo situações extremas, onde as propriedades estão localizadas a mais de mil quilômetros das jazidas.

Por fim, as condições da logística de armazenamento representam outro gargalo para a produção agrícola. Apesar de a grande maioria das propriedades (75%)

estarem localizadas a menos de 38 quilômetros de distância de um armazém, para a metade delas, o número de opções disponíveis a uma distância curta (até 25 quilômetros) seria de no máximo 2 unidades, com uma capacidade máxima de armazenagem de 12 mil toneladas, suficiente para atender uma área de produção agrícola de menos de 4 mil hectares.

Quando se analisam distâncias maiores, tanto o número de armazéns quanto a capacidade de armazenagem aumentam consideravelmente. No entanto, com uma produtividade média de aproximadamente 3 toneladas de soja por hectare, em geral a disponibilidade de silos atenderia à quantidade de soja produzida na área delimitada por esses raios, mas não seria suficiente para as safras de milho e outros grãos.

4.4. Modelagem da mudança do uso e ocupação dos solos

Ao todo, foram construídos oito modelos para o estudo da conversão de áreas para soja em Mato Grosso, utilizando-se como base o mesmo período de análise (2008-2013), alterando-se apenas as variáveis analisadas.

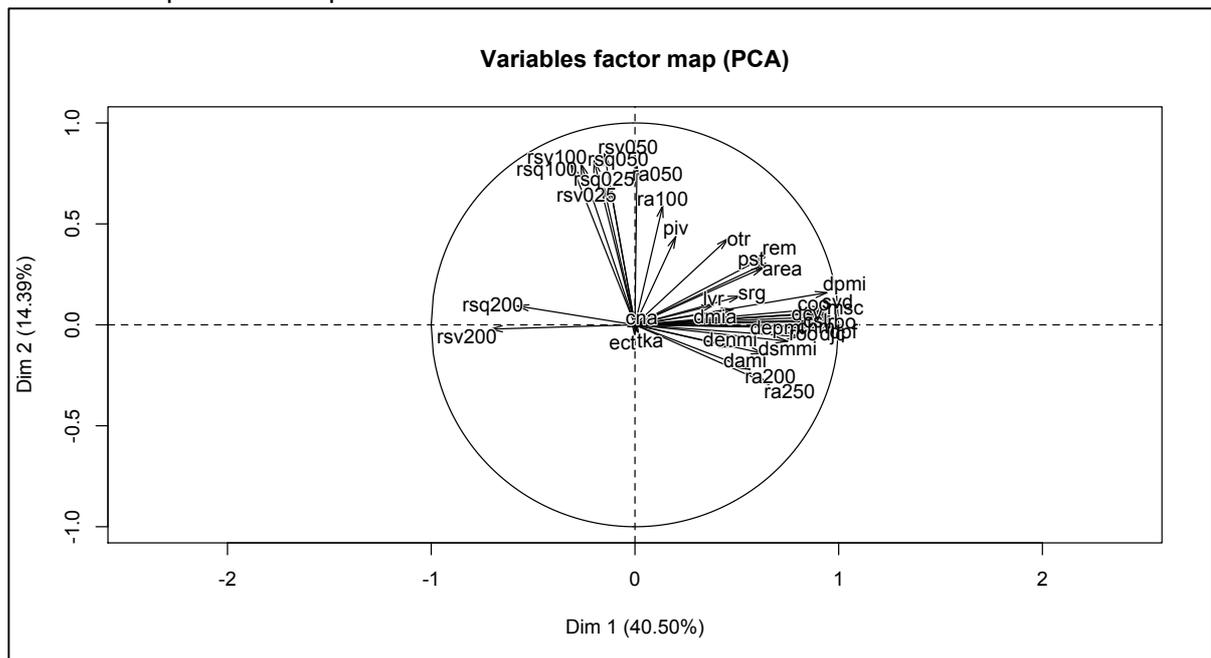
Os três primeiros modelos derivaram da análise de componentes principais, o quarto modelo foi composto pelas variáveis de relevância econômica, o quinto pelas variáveis de relevância agrônômica, o sexto pelas variáveis de importância logística geral, o sétimo pelas variáveis de importância logística da vizinhança e o oitavo, e último, foi derivado das variáveis escolhidas pelos especialistas.

A análise de componentes principais apresentou os resultados indicados na Figura 6 e na Tabela 10. Com essa análise, foi possível concluir que 40,5% dos resultados de conversão podem ser explicados pelo modelo gerado pelo componente 1 e 14,4% explicados pelo componente 2.

O primeiro modelo (equação 1) teve suas variáveis extraídas do componente 1 da análise de componentes principais de todas as variáveis, sendo separadas apenas aquelas que tinham valor acima de $|0,70|$. Como é possível verificar na Tabela 10, no modelo 1, as variáveis que tiveram estimativa com os pesos significativos foram: rentabilidade operacional (roo), receita bruta (rbo), declividade média (dcv), volume médio anual de chuva (chm), número de meses secos (msc), classificação média da severidade da seca (svd), classe solo (csl), distância mínima até estrada pavimentada

(depmi), distância até o município mais próximo (dsmmi), distância até o porto mais próximo (dpmi), distância até a jazida de calcário mais próxima (djc), distância mínima até o porto de Santos (dpf) e capacidade de armazenamento a até 200 km (rsv200). Após o teste de significância para a composição do modelo Logit, a variável “custo operacional (coo)” foi excluída e não compôs o modelo 1 final.

Figura 6 - Resultado da análise de componentes principais (ACP). Mapa com a variação dos autovetores para os componentes 1 e 2



Fonte: Elaborado pelo autor

Já as variáveis do modelo 2 foram derivadas do componente 2 da análise de componentes principais, sendo elas: soma da área agrícola a até 50 km (ra050), capacidade de armazenamento a até 50 km (rsv050), número de armazéns a até 50 km (rsq050), número de armazéns a até 100 km (rsq100). Vale ressaltar que o processo de validação *Step Back* do programa excluiu apenas a variável “número de armazéns a até 100 km (rsq100)”, cujo nível de significância não foi suficiente para compor o modelo.

Como o método de análise de componentes principais possibilitou identificar as variáveis de maior relevância (com coeficiente maior que $|0,70|$) apenas nos componentes 1 e 2, o modelo 3 foi composto pela junção dos componentes 1 e 2.

Tabela 10 - Análise de componentes principais para todas as variáveis do modelo

| Nome | Cod | Dim.1 | Dim.2 | Dim.3 | Dim.4 | Dim.5 | Dim.6 | Dim.7 | Dim.8 | Dim.9 | Dim.10 |
|---|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|
| | | 40,2% | 14,4% | 9,3% | 5,4% | 4,3% | 3,6% | 2,9% | 2,6% | 2,6% | 2,5% |
| Área total da propriedade | área | 0,630 | 0,289 | 0,692 | -0,025 | -0,071 | 0,101 | -0,067 | 0,008 | 0,010 | -0,017 |
| Rentabilidade operacional | roo | 0,893 | -0,009 | -0,181 | 0,014 | -0,104 | 0,026 | -0,053 | -0,006 | -0,009 | 0,058 |
| Custo operacional | coo | 0,948 | 0,065 | -0,147 | 0,056 | 0,051 | 0,034 | -0,078 | 0,001 | -0,007 | 0,050 |
| Receita bruta | rbo | 0,955 | 0,025 | -0,173 | 0,034 | -0,036 | 0,031 | -0,067 | -0,003 | -0,009 | 0,057 |
| Declividade média | dcv | 0,913 | 0,066 | -0,148 | 0,138 | 0,000 | 0,036 | -0,067 | -0,003 | -0,012 | 0,050 |
| Volume médio anual de chuva | chm | 0,968 | 0,032 | -0,134 | 0,041 | 0,074 | 0,023 | -0,050 | 0,004 | -0,001 | 0,035 |
| Número de meses secos | msc | 0,958 | 0,048 | -0,098 | 0,077 | -0,005 | 0,024 | -0,101 | -0,007 | -0,007 | 0,062 |
| Classificação média da severidade da seca | svd | 0,932 | 0,090 | -0,138 | 0,042 | -0,079 | 0,006 | -0,129 | -0,004 | -0,012 | 0,066 |
| Classe solo | csi | 0,888 | 0,065 | -0,074 | 0,199 | 0,000 | 0,064 | 0,029 | -0,001 | -0,037 | 0,051 |
| Área de cana-de-açúcar | cna | -0,033 | -0,010 | 0,005 | 0,018 | -0,057 | 0,026 | 0,099 | 0,908 | 0,334 | 0,203 |
| Área de eucalipto | ect | 0,019 | 0,011 | 0,127 | -0,147 | -0,025 | 0,045 | 0,391 | -0,095 | -0,383 | 0,795 |
| Área de soja | lvr | 0,352 | 0,010 | 0,506 | -0,122 | 0,504 | 0,267 | -0,178 | 0,021 | 0,032 | 0,046 |
| Área irrigada por pivô | piv | 0,193 | 0,418 | 0,500 | -0,526 | 0,028 | 0,016 | 0,292 | -0,005 | 0,033 | -0,150 |
| Área com pastagem | pst | 0,600 | 0,333 | 0,637 | 0,046 | -0,263 | 0,012 | -0,006 | 0,003 | 0,003 | -0,047 |
| Área com remanescente florestal | rem | 0,628 | 0,327 | 0,637 | -0,020 | -0,220 | 0,047 | -0,033 | 0,000 | 0,000 | -0,030 |
| Área com seringueira | srg | 0,509 | 0,134 | 0,457 | 0,434 | -0,363 | 0,023 | -0,252 | 0,004 | -0,018 | 0,055 |
| Área com teca | tka | 0,018 | -0,044 | -0,026 | -0,033 | -0,085 | 0,086 | 0,082 | -0,400 | 0,850 | 0,301 |
| Área com outros usos | otr | 0,339 | 0,429 | 0,605 | -0,382 | -0,052 | 0,004 | 0,238 | -0,004 | 0,023 | -0,115 |
| Distância mínima até área agrícola | dmia | 0,483 | 0,085 | 0,133 | 0,386 | 0,071 | -0,456 | 0,388 | -0,003 | 0,062 | -0,085 |
| Distância mínima até estrada não pavimentada | denmi | 0,466 | -0,117 | -0,022 | -0,242 | 0,661 | 0,176 | -0,041 | 0,019 | 0,030 | -0,046 |
| Distância mínima até estrada pavimentada | depmi | 0,809 | -0,053 | -0,001 | 0,163 | 0,135 | -0,293 | 0,242 | -0,007 | 0,014 | -0,067 |
| Distância mínima até armazém | dami | 0,631 | -0,138 | -0,072 | 0,302 | 0,299 | -0,341 | 0,391 | -0,012 | 0,050 | -0,111 |
| Distância até o município mais próximo | dsmmi | 0,747 | -0,087 | 0,008 | -0,173 | 0,474 | 0,024 | -0,099 | 0,019 | 0,022 | 0,035 |
| Distância até o porto mais próximo | dpmi | 0,944 | 0,167 | -0,133 | -0,022 | 0,056 | 0,009 | -0,040 | 0,005 | 0,003 | 0,038 |
| Distância até a jazida de calcário mais próxima | djc | 0,914 | -0,010 | 0,001 | 0,199 | 0,004 | -0,060 | -0,058 | -0,004 | -0,023 | 0,004 |
| Distância mínima até o porto de Santos | dpf | 0,965 | -0,002 | -0,102 | 0,077 | 0,051 | 0,031 | -0,121 | 0,006 | -0,008 | 0,065 |
| Soma da área agrícola a até 25 km | ra025 | 0,663 | -0,283 | -0,304 | -0,234 | -0,248 | 0,252 | 0,185 | 0,039 | -0,014 | -0,147 |
| Soma da área agrícola a até 50 km | ra050 | 0,008 | 0,786 | -0,170 | -0,350 | 0,097 | -0,203 | -0,093 | 0,030 | 0,017 | 0,053 |
| Soma da área agrícola a até 100 km | ra100 | 0,138 | 0,597 | -0,275 | -0,470 | 0,009 | -0,344 | -0,170 | 0,031 | 0,011 | 0,128 |
| Soma da área agrícola a até 200 km | ra200 | 0,571 | -0,205 | -0,452 | -0,367 | -0,322 | 0,125 | 0,087 | 0,019 | -0,011 | -0,018 |
| Capacidade de armazenamento a até 25 km | rsv025 | -0,121 | 0,682 | -0,217 | 0,193 | 0,054 | 0,404 | 0,248 | -0,014 | -0,011 | -0,085 |
| Capacidade de armazenamento a até 50 km | rsv050 | -0,151 | 0,849 | -0,203 | 0,073 | 0,097 | 0,066 | 0,001 | -0,041 | 0,010 | -0,032 |
| Capacidade de armazenamento a até 100 km | rsv100 | -0,265 | 0,804 | -0,159 | -0,031 | 0,001 | -0,348 | -0,180 | 0,001 | 0,019 | 0,046 |
| Capacidade de armazenamento a até 200 km | rsv200 | -0,714 | -0,036 | 0,444 | 0,260 | 0,221 | -0,120 | -0,120 | -0,013 | 0,005 | 0,127 |
| Número de armazéns a até 25 km | rsq025 | -0,151 | 0,678 | -0,259 | 0,283 | 0,043 | 0,449 | 0,239 | 0,011 | -0,010 | -0,067 |
| Número de armazéns a até 50 km | rsq050 | -0,201 | 0,814 | -0,260 | 0,233 | 0,052 | 0,181 | 0,038 | -0,014 | 0,000 | -0,028 |
| Número de armazéns a até 100 km | rsq100 | -0,313 | 0,804 | -0,198 | 0,140 | -0,044 | -0,166 | -0,096 | 0,012 | -0,005 | 0,055 |
| Número de armazéns a até 200 km | rsq200 | -0,583 | 0,082 | 0,237 | 0,380 | 0,214 | 0,177 | -0,059 | 0,046 | -0,007 | 0,161 |

Fonte: Elaborado pelo autor

Após o processamento computacional, passaram a compor o modelo 3 as seguintes variáveis: rentabilidade operacional (roo), custo operacional (coo), receita bruta (rbo), declividade média (dcv), volume médio anual de chuva (chm), número de

meses secos (msc), classe solo (csl), distância mínima até estrada pavimentada (depmi), distância até o município mais próximo (dsmmi), distância até o porto mais próximo (dpmi), distância mínima até o porto de Santos (dpf), soma da área agrícola a até 50 km (ra050), capacidade de armazenamento a até 50 km (rsv050), capacidade de armazenamento a até 100 km (rsv100), capacidade de armazenamento a até 200 km (rsv200), número de armazéns a até 50 km (rsq050) e número de armazéns a até 100 km (rsq100). As variáveis classificação média da severidade da seca (svd) e distância até a jazida de calcário mais próxima (djc) foram excluídas por apresentarem baixa significância.

Para o modelo 4 foram utilizadas as 3 variáveis econômicas, tendo permanecido, após o processamento computacional, apenas a rentabilidade operacional (roo) e a receita bruta (rbo), isto porque o custo operacional (coo) não foi significativo estatisticamente para compor o modelo Logit 4.

Já no modelo 5, foram utilizadas as variáveis ambientais. O processamento computacional excluiu a variável “classificação média da severidade da seca (svd)”, permanecendo no modelo final as variáveis: declividade média (dcv), volume médio anual de chuva (chm), número de meses secos (msc) e classe solo (csl).

O modelo 6 foi composto pelas variáveis de impacto logístico, compondo o modelo final as variáveis: distância mínima até estrada não pavimentada (denmi), distância mínima até estrada pavimentada (depmi), distância mínima até armazém (dami), distância até o município mais próximo (dsmmi), distância até o porto mais próximo (dpmi), distância até a jazida de calcário mais próxima (djc), distância mínima até o porto de Santos (dpf), capacidade de armazenamento a até 50 km (rsv050), capacidade de armazenamento a até 100 km (rsv100), capacidade de armazenamento a até 200 km (rsv200), número de armazéns a até 25 km (rsq025), número de armazéns a até 50 km (rsq050), número de armazéns a até 100 km (rsq100), número de armazéns a até 200 km (rsq200). A única variável original excluída pelo processo computacional foi a “capacidade de armazenamento a até 25 km (rsv025)”.

As variáveis logísticas de curta distância, ou seja, da vizinhança direta, compuseram o modelo 7. Nesse caso, o processamento computacional não excluiu nenhuma das variáveis consideradas, sendo elas: distância mínima até área agrícola (dmia), soma da área agrícola a até 200 km (ra250), soma da área agrícola a até 50 km (ra050), número de armazéns a até 25 km (rsq025) e número de armazéns a até

50 km (rsq050).

Por fim, o modelo 8 teve suas variáveis selecionadas por um grupo de especialistas que escolheram, originalmente, 23 variáveis. Após o processamento computacional, foram excluídas duas variáveis, a classificação média da severidade da seca (svd) e a capacidade de armazenamento a até 25 km (rsv025), tendo permanecido no modelo as seguintes variáveis: rentabilidade operacional (roo), declividade média (dcv), volume médio anual de chuva (chm), número de meses secos (msc), classe solo (csl), área de soja (lvr), área com pastagem (pst), distância mínima até área agrícola (dmia), distância mínima até estrada não pavimentada (denmi), distância mínima até estrada pavimentada (depmi), distância mínima até armazém (dami), distância até o município mais próximo (dsmmi), distância até o porto mais próximo (dpmi), distância até a jazida de calcário mais próxima (djc), soma da área agrícola a até 200 km (ra250), soma da área agrícola a até 50 km (ra050), soma da área agrícola a até 100 km (ra100), capacidade de armazenamento a até 50 km (rsv050), capacidade de armazenamento a até 100 km (rsv100), número de armazéns a até 25 km (rsq025) e número de armazéns a até 50 km (rsq050).

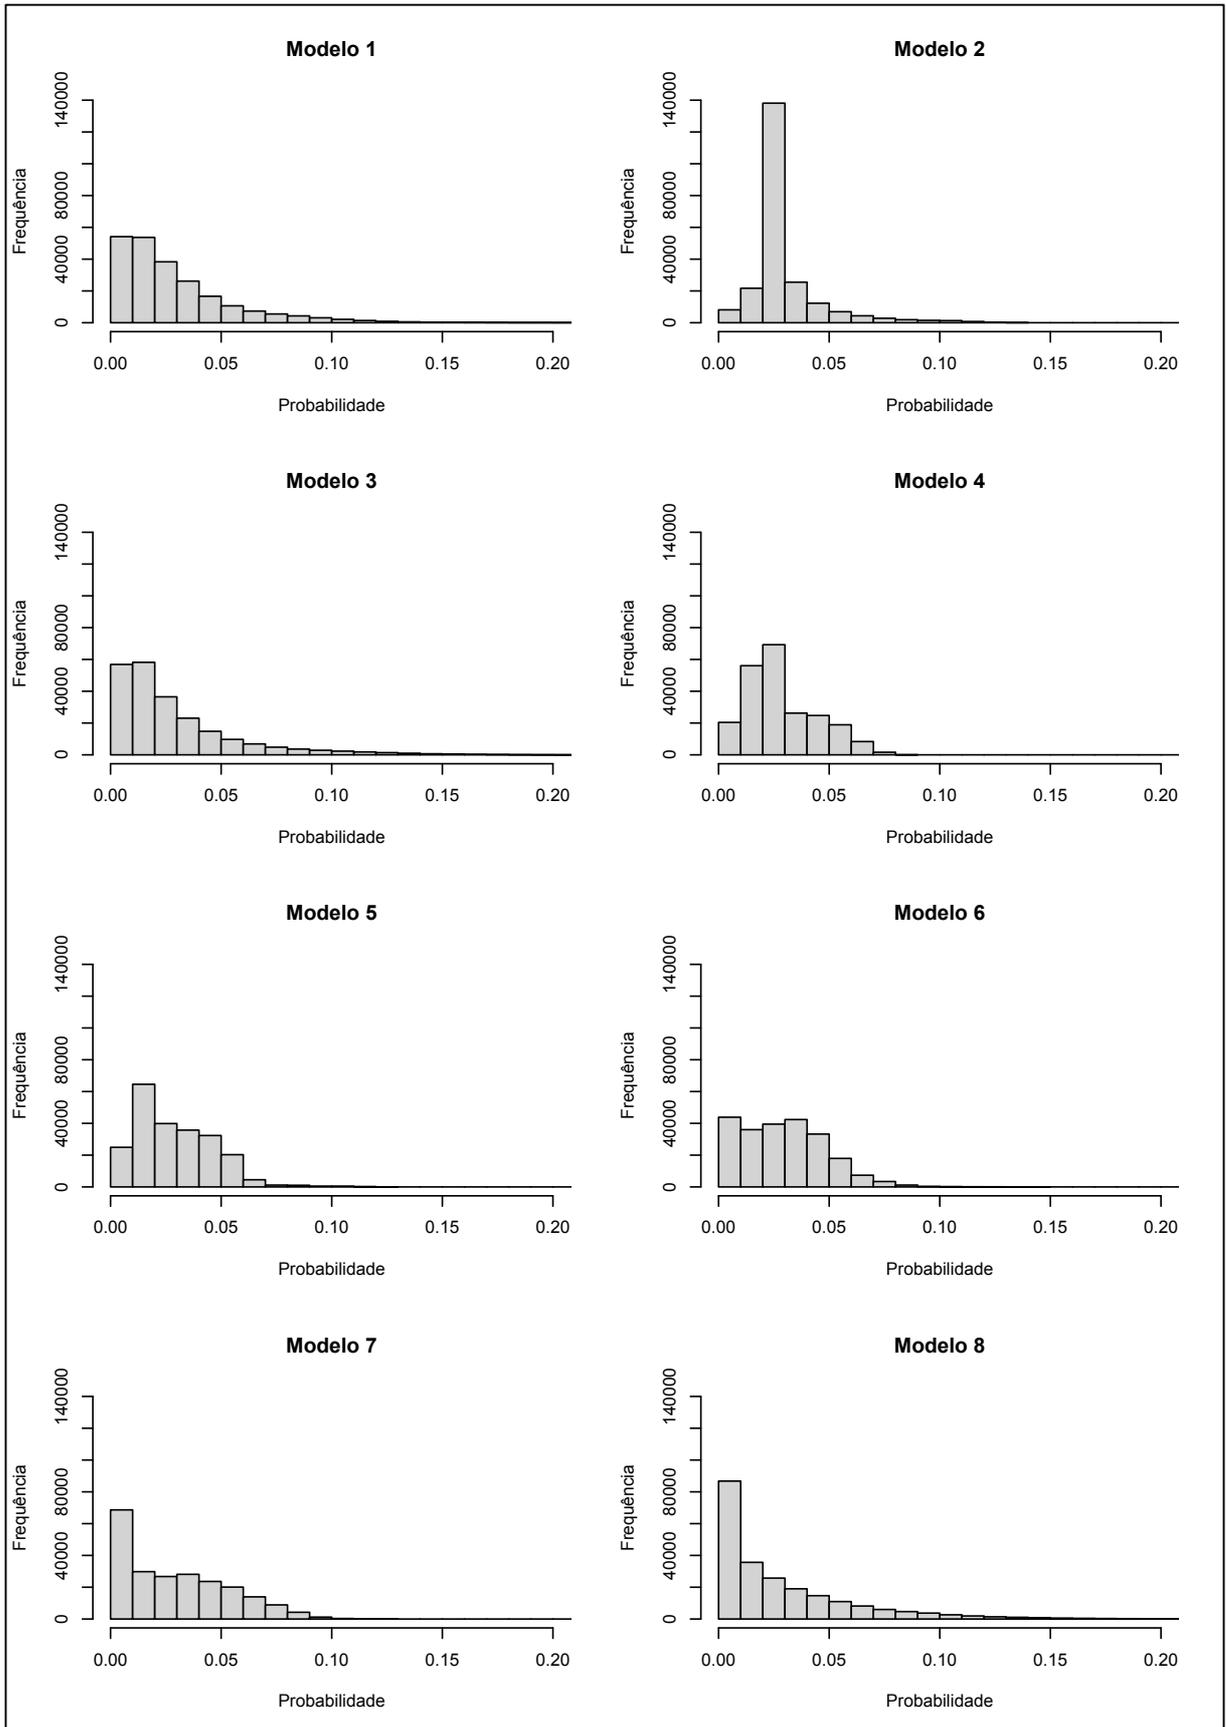
4.5. Análise estatística dos modelos

A análise dos histogramas das distribuições de probabilidade de conversão do uso dos solos dos modelos pode ser observada na Figura 7 que se mostraram mais adequadas à natureza dos dados em análise.

, sendo que visualmente não aparentam seguir uma distribuição normal, fato que também foi confirmado pelo teste estatístico Kolmogorov-Smirnov, cuja hipótese nula foi rejeitada em todos os casos.

Por esse motivo, para a avaliação da capacidade de predição dos modelos foram utilizadas ferramentas de análise não paramétricas, que se mostraram mais adequadas à natureza dos dados em análise.

Figura 7 - Histograma com a distribuição de probabilidade da expansão de soja para cada modelo



Fonte: Elaborado pelo autor

A análise da dispersão gráfica das probabilidades entre as áreas onde ocorreu a conversão e onde não ocorreu (Figura 8) indica que em média, com exceção do modelo 4, a conversão ocorreu onde de fato havia uma probabilidade maior de ocorrer.

Na Tabela 11 é possível confirmar que as áreas que de fato passaram pelo processo de conversão tiveram sua distribuição dos dados visualmente deslocada para cima, atingindo patamares de probabilidade mais elevados que os das áreas onde não houve, indicando, de maneira genérica, que a transformação do uso e ocupação dos solos em 2014 seguiu os mesmos princípios que nortearam esse processo entre os anos de 2008 e 2013.

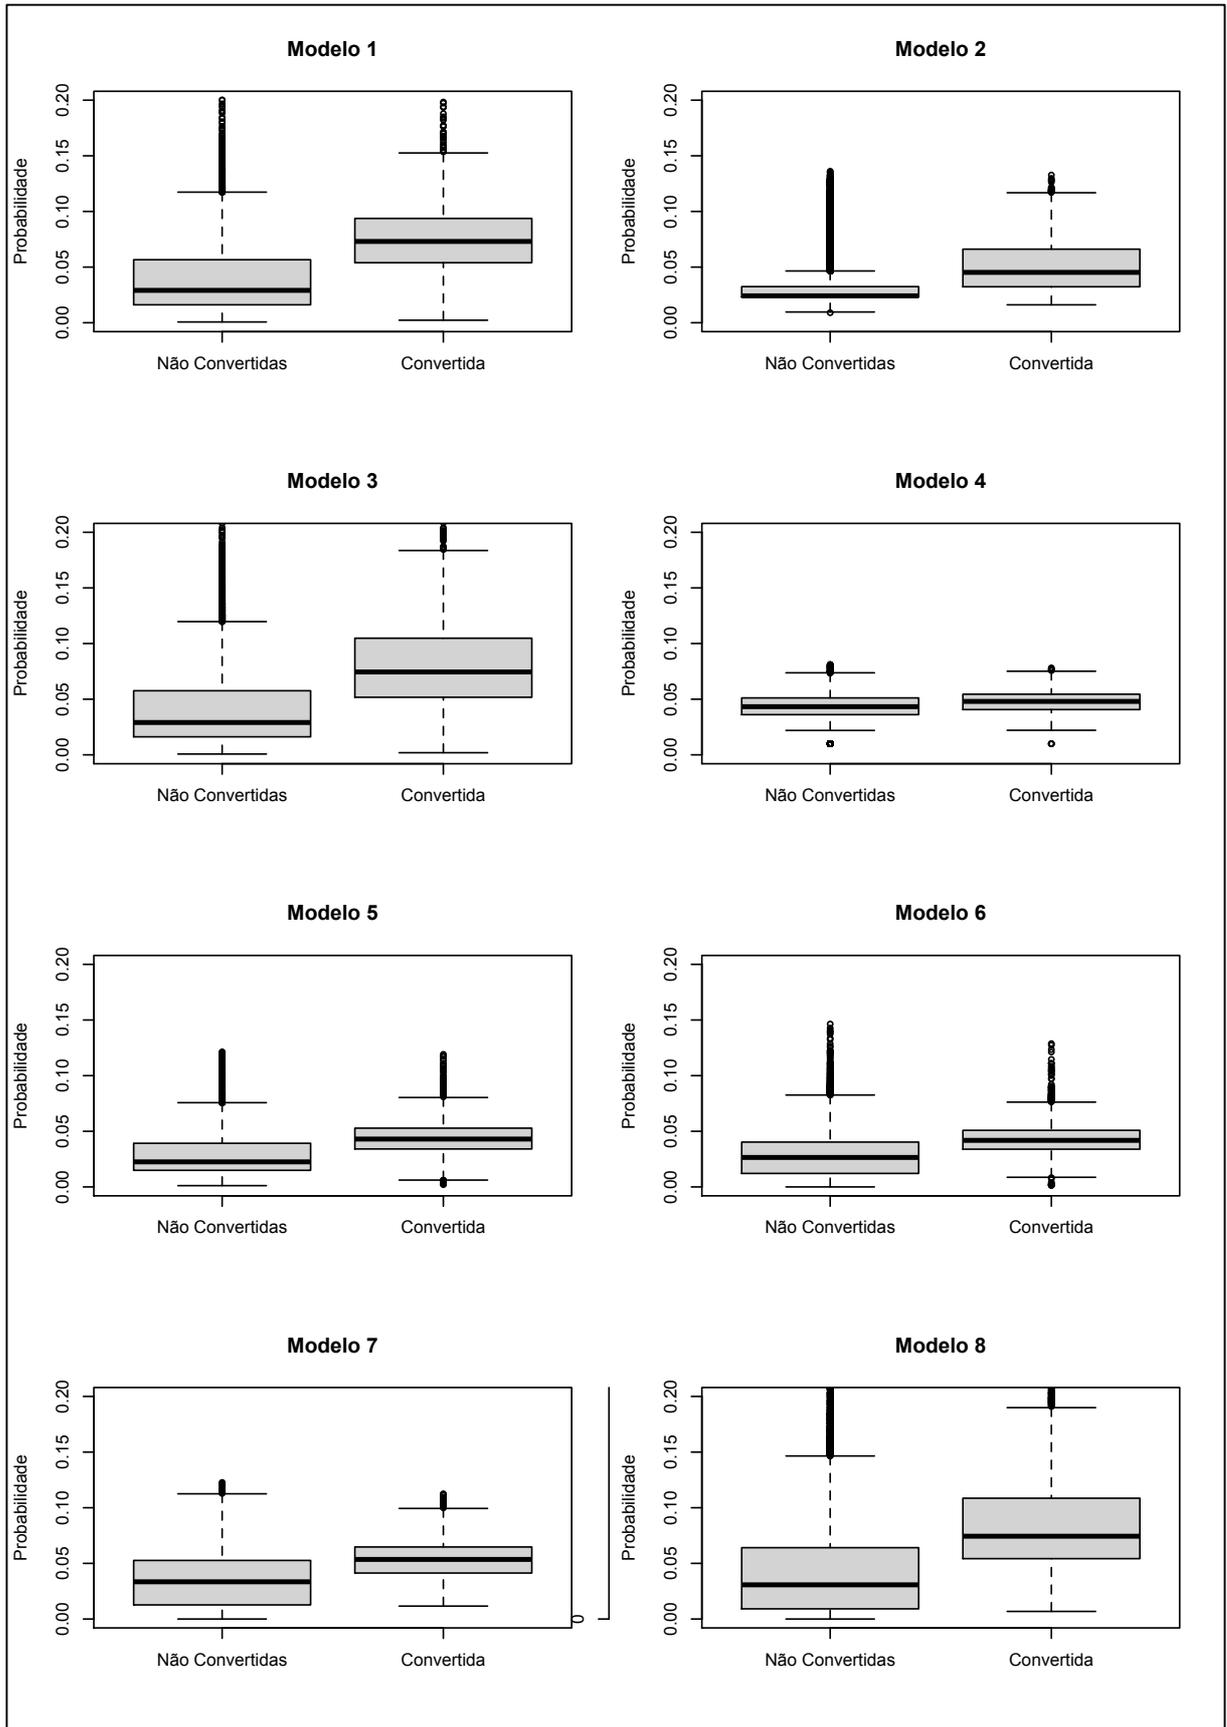
Assim como o indicado visualmente na Figura 8 com os boxplots dos modelos e na Tabela 11, a análise estatística apontou que em todos os modelos houve uma diferença estatística significativa entre o resultado das probabilidades das áreas convertidas e das não convertidas, confirmando que o processo de conversão em 2014 ocorreu de fato onde os modelos apontavam como sendo os mais prováveis. A exceção é o modelo 4, que apesar de ter apresentado diferença estatística entre as probabilidades das áreas onde ocorreu e onde não ocorreu a conversão, registrou uma grande semelhança no boxplot e também resultados muito similares para a mediana.

Tabela 11 - Estatísticas das probabilidades dos modelos testados para as áreas onde ocorreram ou não a conversão das áreas de soja

| | | Mínimo | 1o Quartil | Mediana | Média | 3o Quartil | Máximo |
|----------|-----------------|------------|------------|---------|---------|------------|---------|
| Modelo 1 | Convertidas | 0,00715 | 0,04402 | 0,06584 | 0,06735 | 0,08711 | 0,1941 |
| | Não convertidas | 0,000692 | 0,01663 | 0,03092 | 0,04056 | 0,06018 | 0,2408 |
| Modelo 2 | Convertidas | 0,01643 | 0,02639 | 0,0321 | 0,03714 | 0,04183 | 0,1325 |
| | Não convertidas | 0,009009 | 0,02316 | 0,0246 | 0,03259 | 0,0345 | 0,1361 |
| Modelo 3 | Convertidas | 0,00731 | 0,04392 | 0,06532 | 0,07142 | 0,09447 | 0,2308 |
| | Não convertidas | 0,0007167 | 0,01663 | 0,03094 | 0,0428 | 0,06121 | 0,2368 |
| Modelo 4 | Convertidas | 0,02208 | 0,04219 | 0,04999 | 0,04952 | 0,05618 | 0,07814 |
| | Não convertidas | 0,009938 | 0,03623 | 0,0434 | 0,04229 | 0,0512 | 0,08111 |
| Modelo 5 | Convertidas | 0,002652 | 0,02692 | 0,03855 | 0,03853 | 0,04978 | 0,1103 |
| | Não convertidas | 0,001141 | 0,01527 | 0,0238 | 0,02851 | 0,04063 | 0,1214 |
| Modelo 6 | Convertidas | 0,00000168 | 0,02935 | 0,039 | 0,04004 | 0,04919 | 0,1286 |
| | Não convertidas | 0,00000002 | 0,01294 | 0,02775 | 0,02843 | 0,04126 | 0,1464 |
| Modelo 7 | Convertidas | 0,00000013 | 0,04334 | 0,05371 | 0,05521 | 0,06654 | 0,1221 |
| | Não convertidas | 0,00000006 | 0,01366 | 0,03478 | 0,03562 | 0,05361 | 0,1227 |
| Modelo 8 | Convertidas | 0,0000001 | 0,05994 | 0,08657 | 0,1004 | 0,1211 | 0,9996 |
| | Não convertidas | 0 | 0,009921 | 0,03296 | 0,04357 | 0,06592 | 1 |

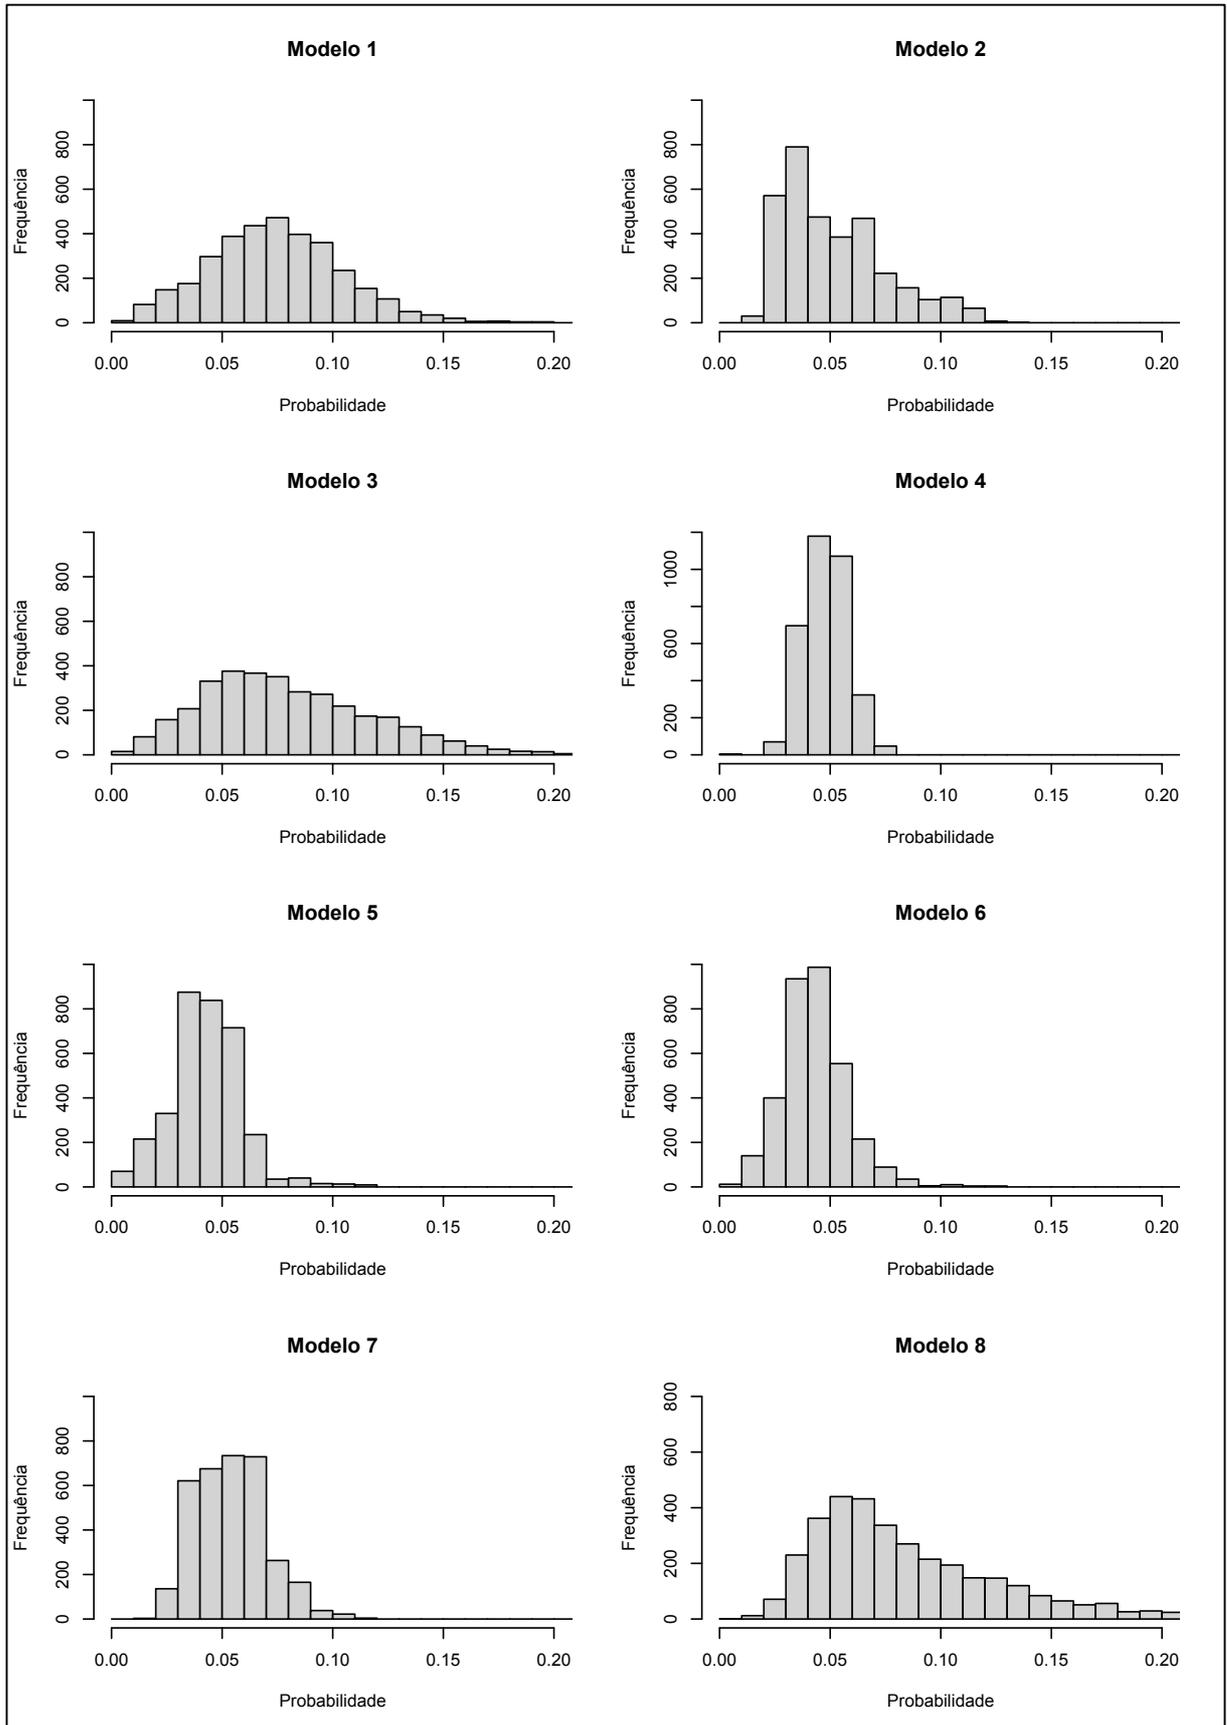
Fonte: Elaborado pelo autor

Figura 8 - Boxplots da distribuição das probabilidades das áreas não convertidas versus as áreas convertidas em 2014



Fonte: Elaborado pelo autor

Figura 9 - Histograma com a dispersão da probabilidade nas áreas onde ocorreu a conversão em 2014



Fonte: Elaborado pelo autor

Por fim, a distribuição das probabilidades das áreas onde ocorreu a conversão (Figura 9) ficou perceptivelmente diferente da distribuição geral da probabilidade de conversão de todas as propriedades (Figura 7), chegando, em alguns casos, a ficar visualmente parecida com a distribuição de uma curva normal.

A sensibilidade de cada modelo às diferentes variáveis, isto é, o impacto da variação de cada variável na probabilidade de expansão da soja, é apresentado na Tabela 12. Esse impacto foi medido pela variação absoluta na probabilidade de expansão da soja, calculada em pontos percentuais, causada por alterações em cada variável. Foram, então, analisados dois casos: quando as variáveis assumem seus valores mínimos e máximos e quando assumem valores médios, que correspondem ao 1º ou 3º quartil de sua função de distribuição.

A medida de quartil facilita a análise de variáveis cujas funções de distribuição concentram-se em torno de classes específicas. Por exemplo, se uma variável como "inclinação" fosse ajustada para seus valores mínimo e máximo, o resultado do modelo seria fortemente afetado. No entanto, dadas as condições naturais de Mato Grosso, isso dificilmente aconteceria no mundo real; razão pela qual, a análise das diferenças entre o 1º e o 3º quartil também é importante.

Em geral, as variáveis ambientais não tiveram grande efeito sobre a probabilidade de expansão da soja. A variação na classe de solo (csl) foi a principal fonte de sensibilidade para o modelo 5, segunda fonte principal para o modelo 1 e terceira fonte principal para os modelos 3 e 8. A severidade das secas (svd) apresentou alta importância relativa nos modelos 1 e 5. As variáveis que controlam o uso da terra anterior (pst, lvr) foram apenas parte do modelo 8 e conduziram a pequenas mudanças de probabilidade de conversão sob condições atuais (ie 1º e 3º quartis), mas grandes mudanças de probabilidade (até 97%) quando valores mínimos e máximos foram considerados.

As variáveis relacionadas às áreas das propriedades circundantes (dmia, ra025 e ra050) apresentaram a maior sensibilidade nos modelos 2, 3, 7 e 8. Somente duas, das três variáveis econômicas originalmente incluídas no modelo 4, foram consideradas significativas. A diferença entre as probabilidades de expansão da soja onde ocorreu vs. onde não ocorreu foi considerável, assim como a mediana entre o primeiro e o terceiro quartil (73%). A probabilidade de conversão mostrou-se particularmente sensível às variáveis logísticas, particularmente silos e instalações de armazenamento, indicando a importância desse tipo de estrutura para futuras

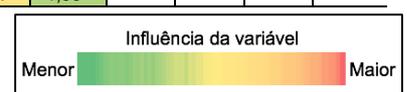
expansões e desenvolvimento agrícola.

Tabela 12 - Impacto da variação de cada variável em cada modelo sobre a probabilidade de conversão para soja, medido em pontos percentuais

| | Modelo 1 | | Modelo 2 | | Modelo 3 | | Modelo 4 | | Modelo 5 | | Modelo 6 | | Modelo 7 | | Modelo 8 | |
|--------|-------------------|-------------------|-------------------|--------------------|-------------------|--------------------|-------------------|-------------------|-------------------|-------------------|-------------------|--------------------|-------------------|-------------------|-------------------|--------------------|
| | 3º - 1º Qt | Max - Min | 3º - 1º Qt | Max - Min | 3º - 1º Qt | Max - Min | 3º - 1º Qt | Max - Min | 3º - 1º Qt | Max - Min | 3º - 1º Qt | Max - Min | 3º - 1º Qt | Max - Min | 3º - 1º Qt | Max - Min |
| área | | | | | | | | | | | | | | | | |
| roo | 2,27 ^A | 7,18 ^A | | | 2,19 ^A | 6,73 ^A | 2,54 ^A | 7,91 ^A | | | | | | | 1,76 ^A | 4,86 ^A |
| coo | Exc | Exc | | | Exc | Exc | 0,19 ^A | 1,01 ^A | | | | | | | | |
| rbo | Exc | Exc | | | Exc | Exc | Exc | Exc | | | | | | | | |
| dcv | 0,26 ^A | 1,64 ^A | | | 0,23 ^A | 1,51 ^A | | | 0,48 ^A | 2,59 ^A | | | | | 0,18 ^A | 1,27 ^A |
| chm | 0,19 ^B | 0,55 ^B | | | 0,17 ^C | 0,52 ^C | | | 0,56 ^A | 1,79 ^A | | | | | 0,64 ^A | 2,05 ^A |
| msc | 0,00 ^A | 4,23 ^A | | | 0,00 ^A | 4,98 ^A | | | 0,00 ^A | 6,55 ^A | | | | | 0,00 ^A | 2,56 ^A |
| svd | 0,89 ^A | 2,79 ^A | | | 0,41 ^A | 1,24 ^A | | | 0,66 ^A | 2,02 ^A | | | | | 0,43 ^A | 1,30 ^A |
| csi | 1,89 ^A | 2,77 ^A | | | 1,79 ^A | 2,68 ^A | | | 2,53 ^A | 3,58 ^A | | | | | 1,42 ^A | 2,29 ^A |
| cna | | | | | | | | | | | | | | | | |
| ect | | | | | | | | | | | | | | | | |
| lvr | | | | | | | | | | | | | | | 0,01 ^A | 97,26 ^A |
| piv | | | | | | | | | | | | | | | | |
| pst | | | | | | | | | | | | | | | 0,17 ^A | 97,38 ^A |
| rem | | | | | | | | | | | | | | | | |
| srg | | | | | | | | | | | | | | | | |
| tka | | | | | | | | | | | | | | | | |
| otr | | | | | | | | | | | | | | | | |
| dmia | | | | | | | | | | | | | 4,75 ^A | 6,72 ^A | 3,14 ^A | 4,60 ^A |
| denmi | | | | | | | | | | | 0,28 ^A | 1,76 ^A | | | 0,23 ^A | 1,49 ^A |
| depmi | 0,50 ^A | 2,28 ^A | | | 0,55 ^A | 2,44 ^A | | | | | Exc | Exc | | | 0,35 ^A | 6,28 ^A |
| dami | | | | | | | | | | | 3,13 ^A | 6,29 ^A | | | 1,20 ^A | 3,56 ^A |
| dsmmi | 0,20 ^A | 1,94 ^A | | | 0,14 ^B | 1,25 ^B | | | | | 0,68 ^A | 9,80 ^A | | | Exc | Exc |
| dpmi | 0,53 ^A | 2,08 ^A | | | 0,44 ^A | 1,77 ^A | | | | | 0,86 ^A | 3,37 ^A | | | 0,57 ^A | 2,26 ^A |
| djc | Exc | Exc | | | | | | | | | Exc | Exc | | | 0,81 ^A | 2,75 ^A |
| dpf | 0,29 ^A | 1,04 ^A | | | 0,28 ^A | 1,02 ^A | | | | | Exc | Exc | | | | |
| ra025 | | | | | | | | | | | | | 1,05 ^A | 2,48 ^A | 0,97 ^A | 2,28 ^A |
| ra050 | | | 3,48 ^A | 41,13 ^A | 1,72 ^A | 13,42 ^A | | | | | | | 1,22 ^A | 6,24 ^A | 0,31 ^C | 1,21 ^C |
| ra100 | | | | | | | | | | | | | | | 0,69 ^A | 2,54 ^A |
| ra200 | | | | | | | | | | | | | | | | |
| rsv025 | | | | | | | | | | | Exc | Exc | | | 0,05 ^C | 0,76 ^C |
| rsv050 | | | 0,63 ^A | 2,33 ^A | 0,19 ^A | 1,11 ^A | | | | | Exc | Exc | | | 0,89 ^A | 19,52 ^A |
| rsv100 | | | 1,18 ^A | 7,37 ^A | 1,71 ^A | 14,17 ^A | | | | | 3,98 ^A | 44,68 ^A | | | 1,11 ^A | 2,47 ^A |
| rsv200 | 0,47 ^A | 1,30 ^A | | | 0,89 ^A | 2,72 ^A | | | | | 1,41 ^B | 4,44 ^B | | | | |
| rsq025 | | | | | | | | | | | Exc | Exc | 0,08 ^D | 1,04 ^D | Exc | Exc |
| rsq050 | | | 0,29 ^D | 1,90 ^D | Exc | Exc | | | | | Exc | Exc | 1,38 ^A | 3,51 ^A | 1,14 ^A | 2,72 ^A |
| rsq100 | | | 1,97 ^A | 3,14 ^A | 2,66 ^A | 3,66 ^A | | | | | 3,36 ^A | 4,73 ^A | | | | |
| rsq200 | | | | | | | | | | | 0,87 ^D | 1,55 ^D | | | | |

Dois cenários foram analisados: diferença de probabilidade quando considerados os valores máximos e mínimos (coluna da direita) e diferença entre os valores do primeiro e do terceiro quartil (colunas da esquerda). $P < 0,001$ (A), $p < 0,01$ (B), $p < 0,05$ (C), $p < 0,1$ (.)

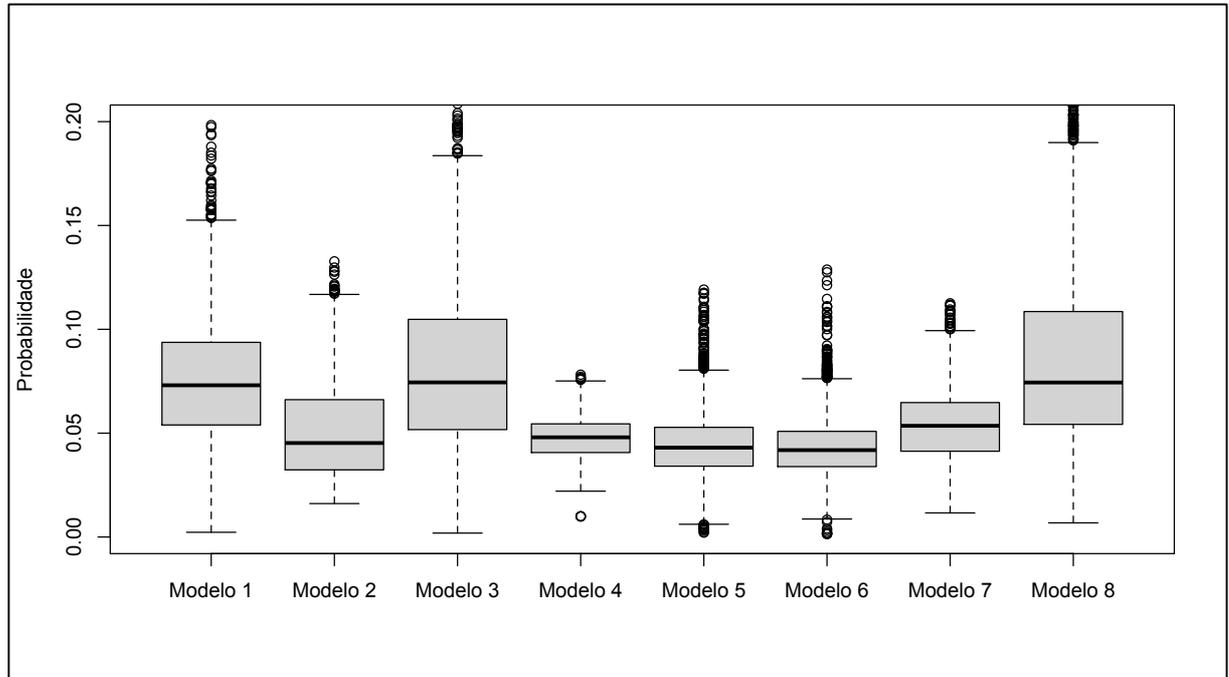
Fonte: Elaborado pelo autor



A análise da dispersão dos modelos não nos permite fazer avaliações conclusivas sobre os modelos testados. Pela Figura 10 é possível observar que os modelos com maior número de variáveis apresentaram maior dispersão de dados entre o primeiro e o terceiro quartil. O modelo com menor dispersão foi o quatro;

justamente, o que apresentou a menor diferença visual em relação à dispersão das probabilidades das áreas onde não ocorreu a transformação do uso dos solos.

Figura 10 - Boxplots da probabilidade das áreas convertidas de soja para cada modelo testado



Fonte: Elaborado pelo autor

Assim como no caso da comparação entre a dispersão de ocorrências de conversão e não conversão de cada modelo, a comparação múltipla não paramétrica das médias das áreas convertidas apontou que todos os modelos eram estatisticamente diferentes entre si.

Para melhorar a interpretação, foi elaborada a Tabela 13, que aponta as diferenças relativas e absolutas entre as estatísticas de cada modelo das áreas onde houve a conversão e onde não houve a conversão em 2014.

Na Tabela 13 fica evidente que o modelo 8 foi o que apresentou as maiores diferenças entre a média das áreas convertidas em relação às não convertidas. O modelo 2 teve a menor sobreposição entre o 1º e o 3º quartil das áreas convertidas em relação às não convertidas, com apenas 10% de sobreposição.

O modelo mais parcimonioso (com menor número de variáveis) foi o 4, com apenas 2 variáveis. No entanto, a diferença da média da probabilidade das áreas convertidas e não convertidas em 2014 foi pequena e a sobreposição média entre o 1º e o 3º quartil foi de 62%, indicando uma menor diferença entre as distribuições de probabilidade entre as áreas onde aconteceu ou não aconteceu a conversão das

áreas para soja; o que demonstra que a análise econômica isolada não seria suficiente para projetar a expansão do uso e ocupação dos solos.

Tabela 13 - Diferença entre as estatísticas de probabilidade de conversão das áreas onde não ocorreram versus as áreas onde ocorreram a conversão para soja em 2014

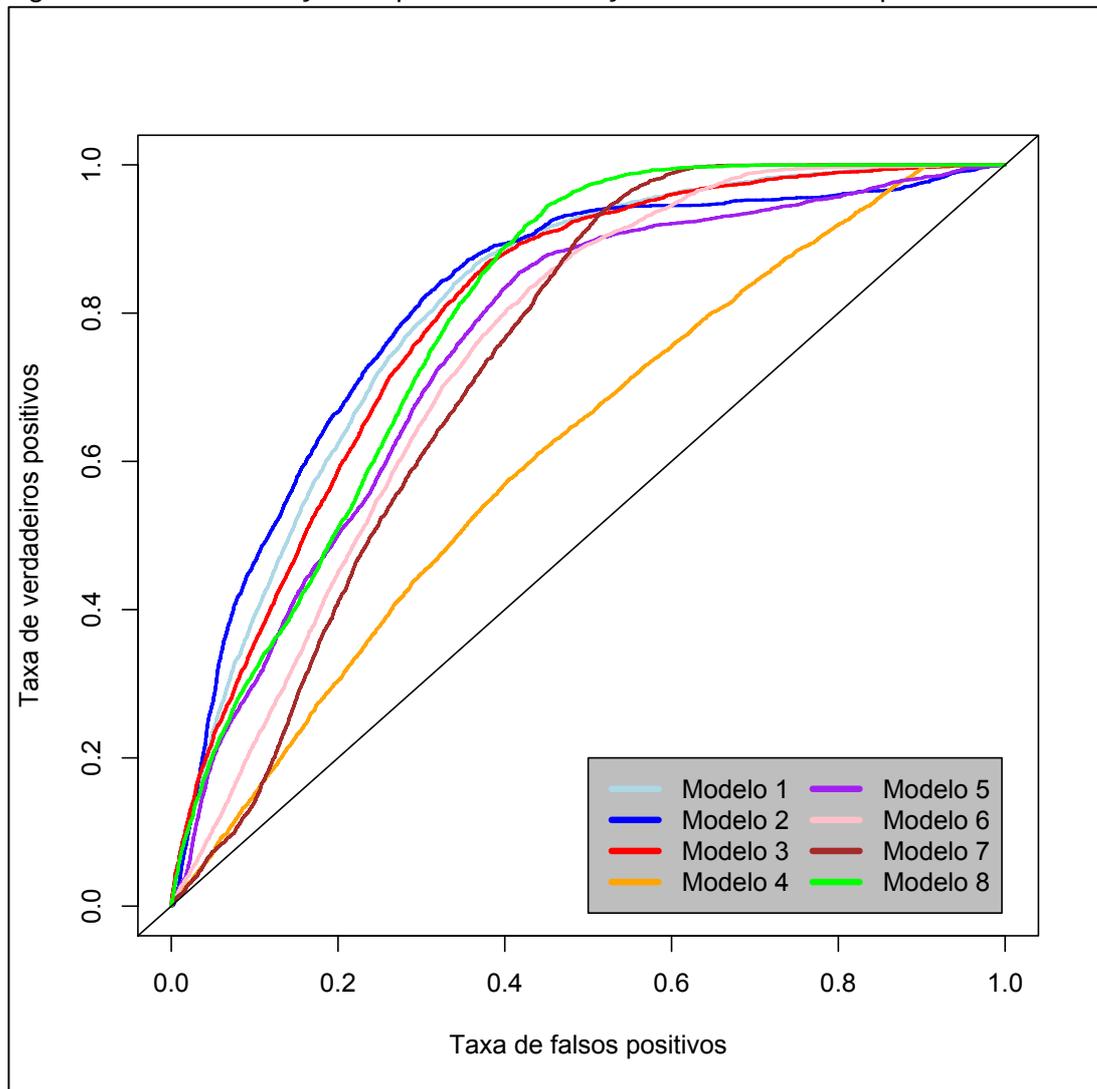
| | Número de variáveis | Mediana | | Média | | Sobreposição entre o 1o e 3o quartil |
|-----------------|---------------------|--------------------|--------------------|--------------------|--------------------|--------------------------------------|
| | | Diferença absoluta | Diferença relativa | Diferença absoluta | Diferença relativa | |
| Modelo 1 | 11 | 0,03492 | 113% | 0,02679 | 66% | 37% |
| Modelo 2 | 5 | 0,0075 | 30% | 0,00455 | 14% | 61% |
| Modelo 3 | 15 | 0,03438 | 111% | 0,02862 | 67% | 36% |
| Modelo 4 | 2 | 0,00659 | 15% | 0,00723 | 17% | 62% |
| Modelo 5 | 5 | 0,01475 | 62% | 0,01002 | 35% | 57% |
| Modelo 6 | 8 | 0,01125 | 41% | 0,01161 | 41% | 49% |
| Modelo 7 | 5 | 0,01893 | 54% | 0,01959 | 55% | 33% |
| Modelo 8 | 21 | 0,05361 | 163% | 0,05683 | 130% | 10% |

Fonte: Elaborado pelo autor

Para melhorar a análise da qualidade de predição dos modelos foi utilizada a metodologia Roc, cujo tamanho da área indica a qualidade de predição, conforme a Figura 11.

A partir das análises gráfica e estatística, foi possível concluir que o modelo 8, com variáveis selecionadas pelos especialistas, obteve a melhor qualidade na predição (maior área abaixo da curva). A área abaixo da curva do modelo 2 foi 0,8157, seguida pelo modelo 1 (0,8107); modelo 3 (0,7995); modelo 8 (0,7949); modelo 5 (0,7553); modelo 6 (0,7453); modelo 7 (0,7346); e finalmente modelo 4 (0,6154).

Figura 11 - Demonstração do poder de simulação de cada modelo pela curva Roc

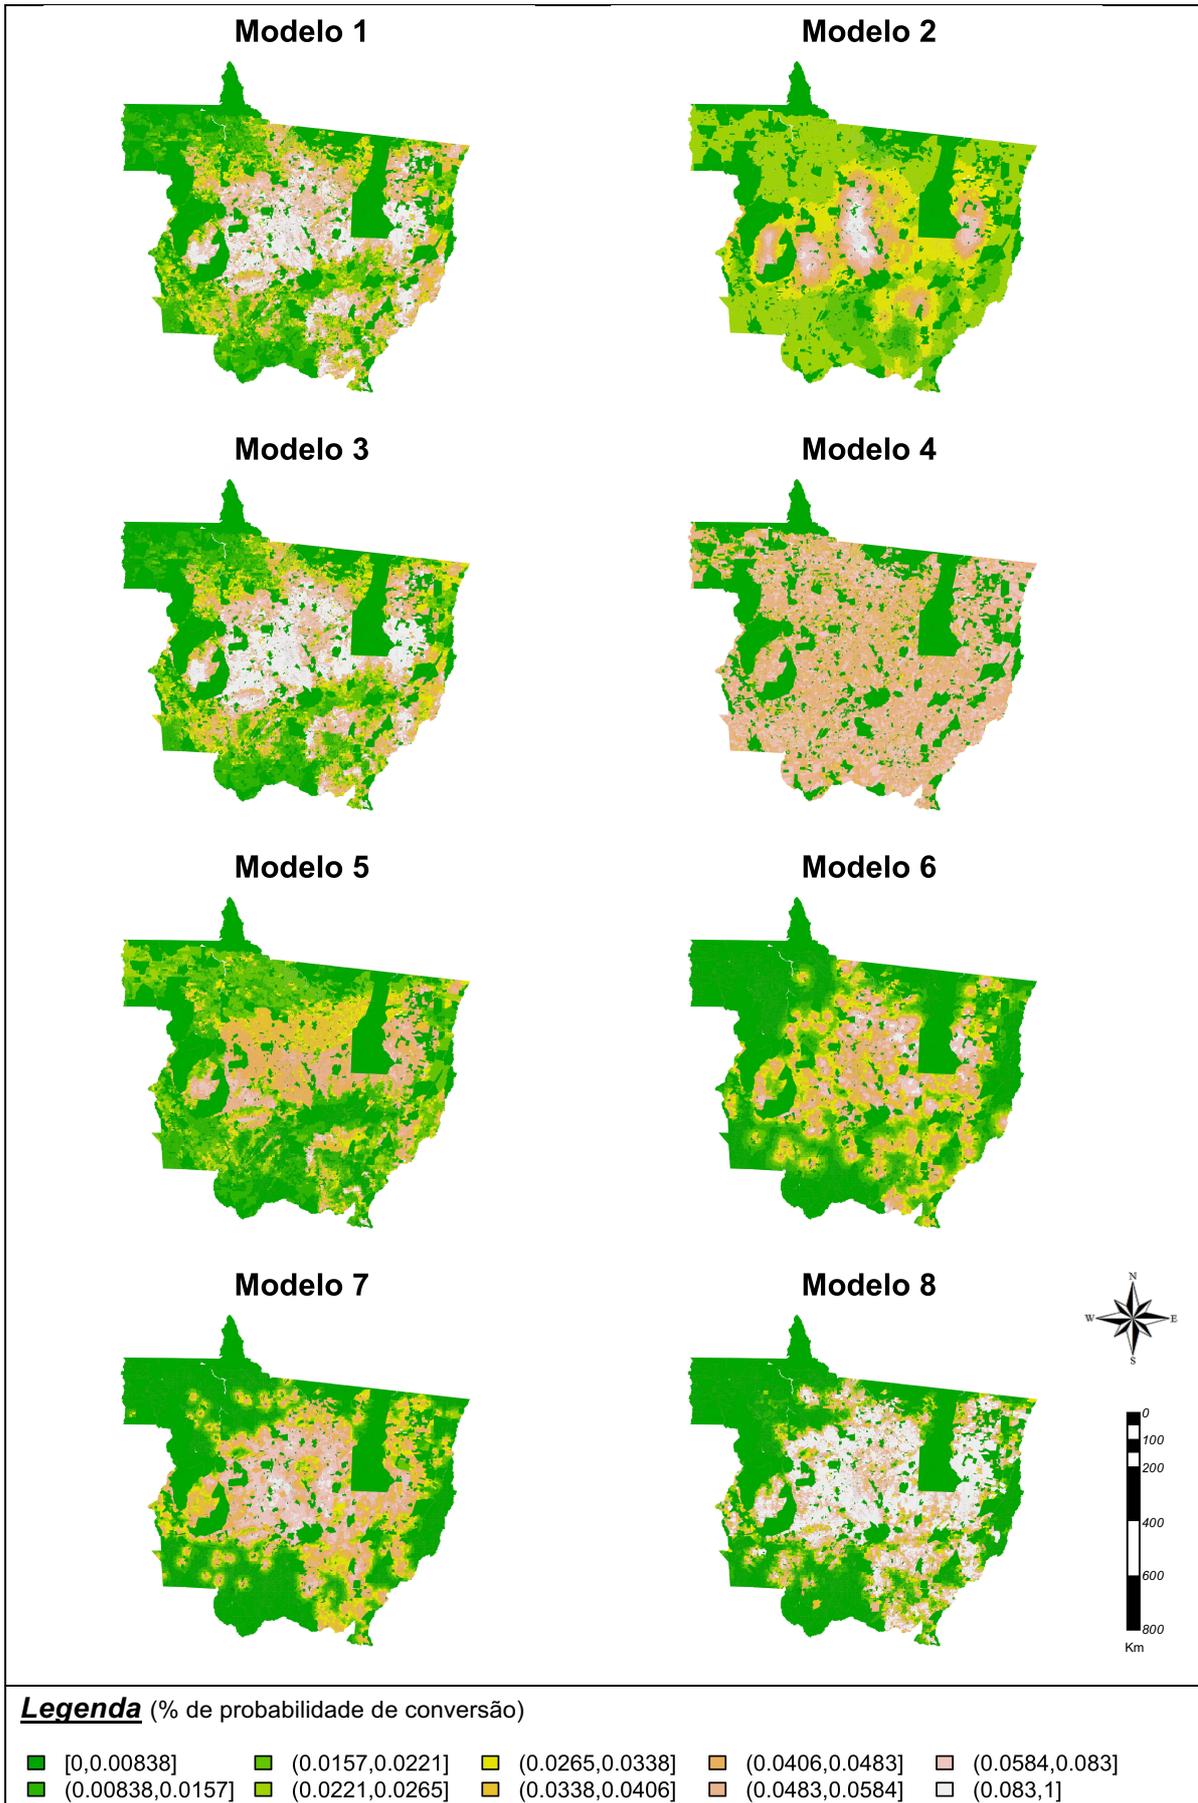


Fonte: Elaborado pelo autor

Os mapas de calor na Figura 12 permitem visualizar as diferenças e semelhanças em cada modelo de projeção de expansão da soja. Isoladamente, as variáveis econômicas (modelo 4) não mostraram um padrão espacial claro da probabilidade de expansão da soja. Embora não haja um contraste nítido entre os modelos, aquele que se baseia nas variáveis ambientais/agronômicas (modelo 5) é o mais discrepante, apontando uma probabilidade relativamente alta de conversão das terras do Noroeste de Mato Grosso (região Amazônica).

Os modelos 6 e 7 sugeriram alguns pontos de calor em áreas localizadas perto de campos de soja existentes. Os melhores modelos preditivos (1, 2, 3 e 8) são bastante semelhantes em relação às maiores probabilidades de expansão da soja em torno da região central do Estado, próximo à BR-163. A principal distinção entre o modelo 2 e os outros foi a homogeneidade das probabilidades em torno de hotspots de conversão.

Figura 12 - Mapas de calor com a dispersão da probabilidade de conversão para soja em cada modelo sobre Mato Grosso



Fonte: Elaborado pelo autor

5. DISCUSSÕES

Os resultados do presente estudo revelaram alguns padrões da dinâmica da expansão da soja no Estado de Mato Grosso e a perspectiva de aumento da demanda mundial, apontada por Alexandratos & Bruinsma (2012), sugere a persistência de tal tendência no futuro. Em regiões tradicionais de produção de soja, onde já existe uma infraestrutura adequada e a cadeia de suprimentos para a soja está mais desenvolvida, ainda é esperada alguma expansão, tendo em vista os efeitos da economia de aglomeração - relatados na literatura quando há o surgimento de um circuito de feedback positivo para o desenvolvimento agrícola existente (Garrett, Lambin, & Naylor, 2013).

É provável que a expansão das áreas de soja nas regiões tradicionais também esteja ligada às variações de preços de um ano para o outro e ao impacto que isso tem na disposição dos agricultores para investir mais na atividade. No entanto, como nossa análise também indica, uma parcela significativa da expansão da soja nos próximos anos pode ocorrer em regiões menos tradicionais, mas com condições agrônômicas adequadas e, possivelmente, preços de terra mais baixos.

A expansão da produção de soja para fazendas que não tinham soja em anos anteriores reflete a reação dos agricultores aos bons resultados econômicos e sua decisão de adquirir novas terras. Isso está alinhado com outros estudos que mostram a maior liquidez dos mercados de terras durante o mesmo período (Informa Economics, 2013) e a disseminação de contratos de aluguel envolvendo a conversão temporária de pastagens em terras cultivadas (Cohn, Gil, Berger, Pellegrina, & Toledo, 2016).

O fato de o preço médio da soja ter sido alto em todo o período analisado limita a nossa compreensão da influência das perdas econômicas ou de preços de mercado menos favoráveis sobre a sua expansão ou contração. Por outro lado, induz a sensibilidade da expansão da soja a pequenas mudanças de lucratividade, bem como outras variáveis de interesse, como a percepção dos produtores sobre a escala de produção e como isso afeta as decisões de produção. Embora maiores níveis de rentabilidade tendam a serem associados a grandes fazendas, o estudo mostrou que pode haver uma variação devido às oscilações de preços anuais.

O preço das terras representa um importante aspecto econômico na análise da expansão da soja, mas não pode ser modelado. Provavelmente, esse foi o motivo de

a expansão da soja em 2012/13 ter ocorrido em maior proporção em fazendas que já produziam soja, o que pode ser explicado em grande parte pela expansão já ocorrida em 2011 e pelo aumento do preço da terra (até 75% maior em algumas regiões), conforme relatado no Informa Economics (2013).

É difícil separar o efeito de diferentes grupos de variáveis (econômico, agrônomo e logístico), pois há interações entre eles. Por exemplo, mesmo os modelos com variáveis agrônômicas (modelo 5) seguem um padrão semelhante em relação aos modelos que consideram apenas as variáveis logísticas, já que a soja é produzida atualmente em regiões com condições naturais favoráveis agronomicamente, onde, ao longo dos últimos anos, foram desenvolvidas estruturas de armazenagem e estradas que influenciam positivamente a probabilidade de conversão de soja.

Analogamente, a proximidade de silos e boas condições logísticas influenciam os custos de produção de soja. Além disso, o poder explicativo das variáveis econômicas é relativo às outras variáveis com as quais é analisada, já que isoladamente (modelo 4) não essas variáveis não tiveram boa capacidade de predição, mas em outros modelos as variáveis econômicas influenciaram nos resultados. No entanto, o efeito da proximidade com outras áreas de soja e a presença de infraestrutura da cadeia de suprimentos a distâncias intermediárias continuaram sendo bastante influentes para a expansão da soja.

As variáveis logísticas também foram consideradas importantes determinantes da expansão da soja. A distância do município até os portos não foi tão crucial, mas as distâncias de cada fazenda até os silos mais próximos e para outras fazendas de soja foram significativamente associadas à conversão de terras. Mesmo que os agricultores tenham percepções diferentes sobre a distância e sejam mais ou menos tolerantes a ela, a viabilidade de se investir na construção de novas instalações de armazenamento diminui se a fazenda estiver próxima de um silo de estrutura comercial (Imea, 2016), sendo melhor contratar um serviço de armazenagem do que construir uma instalação própria. Assim, um novo projeto de investimento de conversão em um local com armazenamento disponível tem menor risco e, conseqüentemente, vai impactar na decisão de conversão.

Independentemente do efeito que cada variável individual possa ter sobre a expansão da soja, nossa análise mostra a importância de analisá-los de forma integrada. Apesar de os custos e receitas influenciarem as decisões dos agricultores

sobre o uso da terra (nossa análise de sensibilidade mostrou que a mudança na lucratividade foi a principal fonte de variação em vários modelos), quando isoladas, essas variáveis econômicas não são boas preditoras da expansão da soja.

Apesar da falta de um mapeamento completo do perímetro das propriedades, as probabilidades de conversão estatisticamente modeladas estavam bem alinhadas com as observações do mundo real em 2014 que, como apontado pelo modelo 2, sendo que a maior parte da expansão da soja ocorreu na região onde foi previsto.

Embora as oscilações de preços sejam mais difíceis de prever e de regular, os investimentos em logística - outro fator crucial para a expansão da soja – afetam diretamente o preço recebido por um produto e, por isso, devem ser planejados levando em conta sua influência sobre o mercado.

Apesar de também não explorada neste trabalho devido à falta de dados, a probabilidade de mudança do uso e ocupação dos solos pode ser afetada pela presença de indústrias, como constatado por Miao (2011), já que geram uma maior demanda por produtos primários, aumentando os preços no seu entorno.

Apesar das incertezas que esses pontos agregam às previsões de expansão da soja em Mato Grosso, o fato de o melhor modelo de regressão ter apontado uma maior probabilidade de expansão da soja em áreas da Amazônia e do Pantanal (Centro-Sul) requer atenção e revela a oportunidade de as entidades governamentais influenciarem na dinâmica do uso da terra.

Outra razão pela qual os resultados devem ser cuidadosamente interpretados diz respeito à conformidade com a legislação ambiental. Embora uma pequena parcela da expansão da soja tenha ocorrido em fazendas que não aparecem nas bases de dados CAR, LAU e/ou GEO, isso não reflete necessariamente a inconformidade desses agricultores. De fato, aqueles que estabeleceram um "Termo de Ajustamento de Conduta" (TAC), se comprometendo com um plano de regularização, já aparecem nesses bancos de dados, independentemente da responsabilidade ambiental que assumiram. Também pode ser o caso de que a conversão da terra, associada com a expansão da soja, tenha ocorrido antes de o TAC ser estabelecido. Do mesmo modo, o fato de alguns agricultores não aparecerem nessas bases de dados não significa necessariamente que não tenham separado uma parte das suas propriedades para fins de conservação.

6. CONSIDERAÇÕES FINAIS

O presente estudo permitiu apontar as áreas de maior probabilidade de expansão da produção de soja no Estado de Mato Grosso. As análises levaram a concluir que as áreas de maior probabilidade são justamente aquelas no entorno das regiões onde a produção já está mais desenvolvida.

Provavelmente, por essa concentração no entorno das áreas onde já existe produção, a presença e a capacidade de armazenamento a curtas distâncias (até 50 km), foram os fatores que definiram o modelo 2 como o de maior acurácia em relação as conversões efetivamente ocorridas no ano de 2014.

Mesmo assim, modelos com variáveis estritamente ambientais (modelo 5), com variáveis estritamente logísticas (modelos 6 e 7) e mesmo os modelos com variáveis mistas (modelos 1, 3 e 8), foram satisfatórios na previsão da conversão de áreas para soja em Mato Grosso.

O único modelo que não gerou um mapa de probabilidade de conversão confiável e que, conseqüentemente, teve o pior desempenho preditivo foi o que possuía apenas variáveis econômicas (modelo 4).

Apesar de, isoladamente, os fatores econômicos terem menor influência na probabilidade de conversão, quando combinadas com outras variáveis, como no caso dos modelos 1, 3 e 8, a importância dessas variáveis aumentou, indicando sua relevância no contexto agrônomo e logístico da propriedade.

As ações visando mitigar problemas ambientais decorrentes de práticas agrícolas – como o uso de defensivos agrícolas, manejo de pragas e manejo dos solos – deverão permanecer focados nas regiões tradicionais, pois é onde a expansão deverá ocorrer primeiro.

Da mesma forma, os investimentos em estradas para o transporte de grãos e armazéns deverão continuar focados nas regiões tradicionais, já que é onde a maior parte das conversões continuarão a ocorrer.

Como já apontado nas discussões, o modelo de maior acurácia (modelo 2), também apontou uma probabilidade mediana de conversão para regiões ambientalmente sensíveis, como o arco da Amazônia e o Pantanal, que, coincidentemente, são regiões com maior carência logística.

Talvez, a alta ocorrência de conversões no entorno das regiões tradicionais

tenha limitado a capacidade preditiva das regiões onde houve uma menor conversão, como no arco da Amazônia. Por isso, uma análise focada nessa região seria interessante no futuro, trazendo maior foco para a defesa e controle dos ativos ambientais da Região Amazônica.

Também deve ser investigada, a expansão da soja em regiões fronteiriças, que pode ser um processo distinto devido aos preços da terra, à especulação e aos objetivos de atores específicos.

Outro ponto importante para a análise futura, seria a incorporação de uma base completa do perímetro das propriedades, que deve passar a existir com o avanço da Lei Ambiental. Essa análise, juntamente com a observação de ciclos econômicos negativos, poderia enriquecer sobremaneira futuros julgamentos.

Da mesma forma, as variáveis que podem representar aspectos culturais, bem como informações sobre atividades econômicas complementares nas propriedades, podem levar a conclusões diferentes sobre o comportamento do uso da terra pelos agricultores.

Uma abordagem pouco explorada, porém, com grande potencial, foi analisada por Pocewicz et al. (2008), que lançaram mão de questionários sobre a intenção declarada do uso e ocupação dos solos. Essa técnica melhorou as previsões, antes baseadas somente em tendências temporais, evitando assim erros de classificação de imagens.

Outras vias de pesquisa identificadas ao longo deste estudo incluem as análises de sensibilidade envolvendo parâmetros logísticos refinados em relação a meios de transporte alternativos, que se mostra crucial para prever a expansão da lavoura de soja em Mato Grosso, dado o alto percentual dos custos de produção associado ao transporte.

REFERÊNCIAS

- Aguiar, A. P. (2006). Modelagem de mudança do uso da terra na amazônia: explorando a heterogeneidade intraregional. *Sensoriamento Remoto - Instituto Nacional de Pesquisas Espaciais*.
- Aguiar, A., Câmara, G., & Escada, M. I. (2007). Spatial statistical analysis of land-use determinants in the Brazilian Amazonia: Exploring intra-regional heterogeneity. *Ecological modelling*, 2(209), pp. 169-188.
- Alexandratos, N., & Bruinsma, J. (2012). World agriculture towards 2030/2050: the 2012 revision. *FAO: ESA Working paper, 03(12)*, p. 4.
- Almeida, P. S., Tiosso, A., & Silva, J. S. (2014). Análises e considerações sobre as influências do código florestal brasileiro na política nacional sobre mudança do clima: lei nº 12.651/12 e suas alterações. *Revista de Estudos Ambientais*, 2(15), pp. 16-24.
- Anderson, L. O., Rojas, E. H., & Shimabukuro, Y. E. (2003). Avanço da soja sobre os ecossistemas cerrado e floresta no Estado do Mato Grosso. *Simpósio Brasileiro de Sensoriamento Remoto(11)*, pp. 19-25.
- Bakker, M. M., Govers, G., Kosmas, C., Vanacker, V., Van Oost, K., & Rounsevell, M. (2005). Soil erosion as a driver of land-use change. *Agriculture, Ecosystems & Environment*, 105(3), pp. 467-481.
- Bowman, M. S., Soares-Filho, B. S., Merry, F. D., Nepstad, D. C., & Rodrigues, H. &. (2012). Persistence of cattle ranching in the Brazilian Amazon: A spatial analysis of the rationale for beef production. *Land Use Policy*, 3(29), pp. 558-568.
- Camargo, L. (2011). *Atlas de Mato Grosso: abordagem socioeconômico-ecológica*. Cuiabá: Entrelinhas.
- Carvalho, T. S., Magalhães, A. S., & Domingues, E. P. (2016). Desmatamento e a contribuição econômica da floresta na Amazônia. *Estudos Econômicos*, 2(46), pp. 501-533.
- Chakir, R., & Parent, O. (2009). Determinants of land use changes: A spatial multinomial probit approach. *Papers in Regional Science*, 88(2), pp. 327-344.
- Cohn, A. S., Gil, J., Berger, T., Pellegrina, H., & Toledo, C. (2016). Patterns and processes of pasture to crop conversion in Brazil: Evidence from Mato Grosso State. *Land Use Policy(55)*, pp. 108-120.
- Conab. (2010). *Custo de produção agropecuária: A metodologia da CONAB*. Brasília.
- Conab. (jan de 2015). (Companhia Nacional de Abastecimento) Fonte: <http://www.conab.gov.br/>
- Embrapa e Inpe. (2012). *TerraClass. Levantamento de informações de uso e cobertura da terra na Amazônia*. Belém: Embrapa.
- Espindola, G. M., Aguiar, A. P., Pebesma, E., Câmara, G., & Fonseca, L. (2012). Agricultural land use dynamics in the Brazilian Amazon based on remote sensing and census data. *Applied Geography(32)*, pp. 240-252.

- Fiesp. (2015). *Outlook Fiesp. 2025: projeções para o agronegócio brasileiro*. São Paulo. Fonte: <http://hotsite.fiesp.com.br/outlookbrasil/2025/files/assets/common/downloads/publication.pdf>
- Funai. (Atualização contínua). Terra Indígena (Regularizada, Homologada, Declarada, Delimitada e Área em Estudo). Brasília.
- Garrett, R. D., Lambin, E. F., & Naylor, R. L. (September de 2013). The new economic geography of land use change: Supply chain configurations and land use in the Brazilian Amazon. *Land Use Policy*, 34, pp. 265-275.
- Gil, A. C. (1999). *Como elaborar projetos de pesquisa* (4 ed.). São Paulo: Atlas.
- IBGE. (jan de 2015). (Instituto Brasileiro de Geografia e Estatística) Fonte: <http://www.sidra.ibge.gov.br/>
- Imea. (jan de 2015). (Instituto Mato-Grossense de Economia Agropecuária) Fonte: <http://www.imea.com.br/>
- Imea. (2015). *Projeções do Agronegócio em Mato Grosso para 2025*. Cuiabá.
- Imea. (2016). *Fast Tool Armazenagem*. Fonte: <http://www.aprosoja.com.br/produtor/simuladores/>
- Imea e Sinoptica. (2014). *Sistema de Informações Geográficas de Mato Grosso (SIGA-MT)*. Cuiabá.
- Informa Economics, F. N. (2013). *ANUALPEC 2013: anuário da pecuária brasileira*. São Paulo.
- Irwin, E. G., & Geoghegan, J. (2001). Theory, data, methods: developing spatially explicit economic models of land use change. *Agriculture, Ecosystems & Environment*, 1(85), pp. 7-24.
- Jasinski, E., Morton, D., DeFries, R., Shimabukuro, Y., Anderson, L., & Hansen, M. (2005). Physical landscape correlates of the expansion of mechanized agriculture in Mato Grosso, Brazil. *Earth Interactions*, 16(9), pp. 1-18.
- Li, J., Deng, X., & Seto, K. C. (2013). The impact of urban expansion on agricultural land use intensity in China. *Land Use Policy*, 35, pp. 33-39.
- Macrologística. (2013). *Centro Oeste Competitivo*. São Paulo. Fonte: <http://www.ampa.com.br/arquivos/publicacoes/19122013032704.pdf>
- Mann, M. L., Kaufmann, R. K., Bauer, D. M., Gopal, S., Nomack, M. W., & Soares-Filho, B. S. (2014). Pasture conversion and competitive cattle rents in the Amazon. *Ecological Economics*,(97), pp. 182-190.
- Mann, M. L., Kaufmann, R. K., Bauer, D., Gopal, S., Vera-Diaz, M. D., Nepstad, D., & Amacher, G. S. (2010). The economics of cropland conversion in Amazonia: the importance of agricultural rent. *Ecological Economics*, 7(69), pp. 1503-1509.
- Mapa. (2016). *Projeções do Agronegócio : Brasil 2015/2016 a 2025/2026. Projeções de longo prazo*. Brasília.
- Masuda, T., & Goldsmith, P. D. (2009). World Soybean Production: Area Harvested, Yield, and Long-Term Projections. 12(4), pp. 143-161.
- Miao, R. (2011). *The Land-use change effect of ethanol plants in Iowa: 1997-2009*. Working paper, Iowa State University, Ames, Iowa.

- MMA. (Atualização contínua). *Unidades de conservação do Brasil*. Fonte: <http://mapas.mma.gov.br/i3geo/datadownload.htm>
- Moreira, M. L. (2007). *Mato Grosso: solos e paisagens*. Cuiabá: Entrelinhas.
- OECD. (2015). *Oecd Environmental Performance Reviews: Brazil 2015*. Paris.
- Pocewicz, A., Nielsen-Pincus, M., Goldberg, C. S., Johnson, M. H., Morgan, P., Force, J. E., & Vierling, L. (2008). Predicting land use change: comparison of models based on landowner surveys and historical land cover trends. *Landscape Ecology*, 23(2), pp. 195-210.
- Prati, R. C., Batista, G., & Monard, M. C. (2008). Curvas ROC para avaliação de classificadores. *Revista IEEE América Latina*, 6(2), pp. 215-222.
- Radeloff, V. C., Nelson, E., Plantinga, A. J., Lewis, D. J., Helmers, D., Lawler, J. J., & Lonsdorf, E. (2012). Economic-based projections of future land use in the conterminous United States under alternative policy scenarios. *Ecological Applications*, 22(3), pp. 1036-1049.
- Rivero, S., Almeida, O., Ávila, S., & Oliveira, W. (2009). Pecuária e desmatamento: uma análise das principais causas diretas do desmatamento na Amazônia. *Nova economia*, 1(19), pp. 41-66.
- Schmitz, C., Van Meijl, H., Kyle, P., Nelson, G. C., Fujimori, S., Gurgel, A., & Sands, R. (2014). Land-use change trajectories up to 2050: insights from a global agro-economic model comparison. *Agricultural economics*, 45(1), pp. 69-84.
- Serneels, S., & Lambin, E. F. (2001). Proximate causes of land-use change in Narok District, Kenya: a spatial statistical model. *Agriculture, Ecosystems & Environment*, 85(1), pp. 65-81.
- Simões, M., Pereira, S., & Ferraz, R. (2014). Geração de cenários de mudança de uso do solo na amazonia legal brasileira em função do agronegócio e da aplicação de políticas públicas. Anais do Simpósio Regional de Geoprocessamento e Sensoriamento Remoto. *Geonordeste 2014*, (pp. 18-21). Aracaju.
- Ustaoglu, E., Perpiña Castillo, C., Jacobs-Crisioni, C., & Lavallo, C. (2016). Economic evaluation of agricultural land to assess land use changes. *Land Use Policy*, 56, pp. 125-146.
- Varella, C. A. (2008). *Análise de componentes principais*. Seropédica, RJ.
- Veldkamp, A., & Lambin, E. F. (2001). Predicting land-use change. *Agriculture, ecosystems & environment*, 85(1), pp. 1-6.
- Verburg, R., Rodrigues Filho, S., Debortoli, N., Lindoso, D., Nesheim, I., & Bursztyn, M. (2014). Evaluating sustainability options in an agricultural frontier of the Amazon using multi-criteria analysis. *Land Use Policy*(37), pp. 27-39.
- Verburg, R., Rodrigues Filho, S., Lindoso, D., Debortoli, N., Litre, G., & Bursztyn, M. (2014). The impact of commodity price and conservation policy scenarios on deforestation and agricultural land use in a frontier area within the Amazon. *Land Use Policy*(37), pp. 14-26.
- Wear, D. N., & Bolstad, P. (1998). Land-use changes in southern Appalachian landscapes: spatial analysis and forecast evaluation. *Ecosystems*, 1(6), pp. 575-594.
- Weinhold, D., & Reis, E. (2008). Transportation costs and the spatial distribution of land use in the Brazilian Amazon. *Global Environmental Change*, 18(1), pp. 54-68.