

# **O impacto da renda da terra sobre a mudança do uso do solo na Amazônia Legal e a importância de incorporar a interdependência espacial em modelos econométricos de uso da terra**

**Autores: Gêssica Cardoso P. Souza<sup>1</sup>; Pedro Vasconcelos Maia do Amaral<sup>2</sup>**  
**Área temática: Teoria Econômica e Economia Aplicada**

## **RESUMO**

As mudanças nos padrões de uso da terra, *Direct Land Use Change* (LUC) e *Indirect Land Use Change* (ILUC), afetam significativamente o meio ambiente e o bem-estar econômico e social. Dessa forma, o principal objetivo dessa pesquisa foi verificar o impacto do retorno econômico da terra sobre a dinâmica da mudança do uso do solo na Amazônia Legal. O objetivo secundário foi verificar o quanto a incorporação da dimensão espacial no modelo econométrico provoca melhorias preditivas nas estimações. De modo geral, a renda da terra agrícola parece impactar na mudança do uso da terra significativamente e as estimações por SEM-GMM e KKP-GMM não pareceram melhorar a precisão das estimações.

**Palavras-Chave:** uso da terra; econometria espacial; renda da terra

**JEL:** C53, Q24; R14

---

<sup>1</sup> Mestre em Economia Aplicada/ DER-UFV. Doutoranda em Economia Aplicada/ CEDEPLAR – UFMG. Membro do grupo NEMEA - Núcleo de Estudos em Modelagem Econômica Aplicada

<sup>2</sup> Ph.D. em Economia, Land Economy Department, University of Cambridge, 2013. Professor Adjunto do Departamento de Ciências Econômicas da UFMG

## 1 Introdução

As mudanças nos padrões de uso da terra, *Direct Land Use Change* (LUC) e *Indirect Land Use Change* (ILUC), afetam significativamente o meio ambiente (biodiversidade, poluição da água, erosão do solo e mudanças climáticas) e o bem-estar econômico e social (Jean-Sauveur et al., 2014). Tais mudanças produzem importantes implicações para uma ampla variedade de questões como a segurança alimentar, conservação da vida selvagem, distribuição de terras, sequestro de carbono, dentre outras (Turner et al., 2007; Lapola *et al.*, 2010; Bateman et al., 2013; Gazzoni, 2014). A capacidade de prevê-las assim como compreender sua dinâmica são questões úteis para os formuladores de políticas na avaliação de práticas já existentes ou na elaboração de novas políticas amigáveis ao meio ambiente (Gallo et al., 2013; Jean-Sauveur et al., 2014).

Diversos fatores influenciam no processo de mudança do uso da terra. Dentre eles, vale destacar as condições climáticas, como chuvas e temperatura, bem como fatores socioeconômicos, como os preços dos insumos, características da tecnologia de produção e a renda da terra. Existem ainda os fatores políticos, como os subsídios para reflorestamento ou impostos sobre o desmatamento. Todos esses estão relacionados à localização, o que justifica a importância de se considerar o espaço no processo de modelagem. Apesar disso, a maioria dos estudos de uso da terra com base em modelos de dados espacialmente explícitos evitam a interdependência espacial (ou autocorrelação espacial) entre observações usando procedimentos ad hoc (Gallo et al., 2013).

Segundo Verburg et al. (2004), os padrões de uso da terra quase sempre exibem autocorrelação espacial. São diversas as possíveis fontes: as características ambientais semelhantes no espaço; as interações estratégicas entre os tipos de uso da terra; os erros de medição das variáveis; desajustes ou integração de base de dados de diferentes escalas; variáveis latentes não observáveis espacialmente correlacionadas, dentre outras. Diversas literaturas econométricas espaciais fornecem maneiras de lidar com a autocorrelação espacial. No entanto, a incorporação da dimensão espacial nos modelos de uso da terra apresenta vários desafios relacionados à estimativa econométrica, teste de hipóteses e predição (Anselin, 2007; Brady e Irwin, 2011).

Dessa forma, o principal objetivo dessa pesquisa foi verificar o impacto do retorno econômico da terra sobre a dinâmica da mudança do uso do solo. Contribuindo, dessa forma, com os poucos estudos que fazem uso de modelos econométricos, para o entendimento da dinâmica da alocação da terra na região da Amazônia Legal. O objetivo secundário foi verificar o quanto a incorporação da dimensão espacial no modelo provoca melhorias preditivas nas estimações, quando comparado com modelos não espaciais. Assim como em Gallo et al. (2013), os efeitos espaciais são incorporados através de um processo autorregressivo do erro espacial e considerando a heterogeneidade individual dos dados em painel, por meio de uma especificação de componente do erro, como sugerido por Kapoor et al. (2007).

Após esta seção introdutória, a seção 2 apresenta brevemente a região estudada nessa pesquisa. Na seção 3 é apresentado o referencial teórico. Na seção 4 as metodologias adotadas. Na seção 5 a descrição das variáveis dependentes e independentes, o tratamento da base de dados, as fontes e a análise descritiva dos dados. Na seção 6 são apresentados os resultados. Por fim, na seção 7, as conclusões.

## 2 A região de estudo

A Amazônia Legal representa 59% do território brasileiro, abrangendo os estados do Acre, Amapá, Amazonas, Mato Grosso, Pará, Rondônia, Roraima, Tocantins, Maranhão e Goiás, sendo que, nos três últimos, a abrangência é parcial, compreendendo 98% da área do Tocantins, 79% do Maranhão e apenas 0,8% de Goiás (BRASIL, 2008). Dentro desse recorte vivem cerca de 23 milhões de pessoas, o que equivale a aproximadamente 13% da população nacional, de acordo com o Censo Demográfico 2010. A população é distribuída por 775 municípios. Em relação aos biomas, a floresta tropical amazônica é predominante e o bioma cerrado corresponde a 20%.

A região é conhecida por deter 1/3 das florestas tropicais úmidas do planeta e por apresentar índices alarmantes de desmatamento desde a década de 60, quando o processo de desflorestamento ganhou força (Andersen et al., 2002). De acordo com o PRODES (INPE, 2016), no ano de 1988 a área total desmatada na Amazônia foi de 21 mil km<sup>2</sup>, em 1995 o desmatamento anual chegou a quase 30 mil km<sup>2</sup>, ápice da série histórica. Depois de anos de altas taxas, observa-se a partir de 2004 uma queda do desflorestamento que durou até os anos de 2012. Em 2005, por exemplo, a taxa ficou um pouco abaixo de 20 mil km<sup>2</sup> e em 2012 chegou a 4 mil km<sup>2</sup>, a menor taxa da série histórica. A partir de 2013 o índice voltou a aumentar gradativamente, chegando a 7 mil km<sup>2</sup> em 2016.

As causas do desmatamento na Amazônia podem ser classificadas como próximas ou não próximas, de acordo com Geist e Lambin (2001 e 2002). As causas próximas estão associadas às mudanças no uso do solo, afetando diretamente o ambiente e a cobertura vegetal. As causas não próximas ou subjacentes estão associadas ao crescimento dos mercados. São consideradas causas não próximas o aumento da densidade demográfica (IGLIORI, 2008); a insegurança sobre os direitos de propriedade da terra (ARAÚJO et al., 2009); os investimentos do governo em infraestrutura (FEARNSIDE, 2001b); crescimento da demanda mundial por commodities (RUDEL et al., 2009b) e políticas fiscais e creditícias de incentivo a expansão da fronteira agrícola (WALKER et al., 2000).

Segundo o IBGE (2003), a substituição da cobertura natural por pastos para pecuária extensiva, com a extração prévia das madeiras de lei, seria o principal driver de desmatamento na Amazônia. A área convertida em pastagens corresponde a cerca de 70% da área total desmatada na região (Aguiar et al., 2007). Além disso, existe ainda o avanço das plantações de soja que ocorrem sobre as florestas e pastagens existentes. A ocupação dos pastos por plantações de soja causam a expansão das pastagens sobre a floresta, o que caracteriza um processo de ILUC, com impactos significativos na região, como observado em Arima et al. (2011).

De acordo com os dados de monitoramento remoto fornecidos pelo TerraClass<sup>3</sup>, e da Produção Agrícola Municipal – IBGE, é possível analisar a evolução da mudança do uso da terra nos anos de 2004, 2008, 2010, 2012 e 2014, na Amazônia Legal<sup>4</sup>. De acordo com a Tabela 1, os solos destinados a agricultura apresentaram a maior variação no período entre 2004 e 2014, um aumento de 57%. Em 2004, 5,32 milhões de hectares de terras foram destinados a agricultura, em 2014, 8,36 milhões de hectares. As florestas diminuíram 3%, o que equivale a aproximadamente 10 milhões de hectares a menos de áreas nativas no período. As áreas de pastagens aumentaram 13%, o que equivale a aproximadamente 5 milhões de

<sup>3</sup> O Projeto TerraClass é resultado de uma parceria entre o Instituto Nacional de Pesquisas Espaciais – Centro Regional da Amazônia (INPE/CRA), Embrapa Amazônia Oriental (CPATU) e a Embrapa Informática Agropecuária (CNPTIA). O projeto tem como objetivo produzir mapas sistêmicos de uso e cobertura das terras desflorestadas da Amazônia Legal Brasileira. [http://www.inpe.br/cra/projetos\\_pesquisas/dados\\_terraclass.php](http://www.inpe.br/cra/projetos_pesquisas/dados_terraclass.php)

<sup>4</sup> Os dados foram compilados de acordo com a necessidade da pesquisa em questão. O processo de compatibilização das bases de dados e de agregação das classes de uso da terra segue detalhado na seção 5

hectares. As áreas desmatadas apresentaram uma queda de 85%, em concordância com os dados divulgados pelo PRODES (INPE, 2016). Por fim, as áreas com outros usos, que incluem áreas urbanas, silvicultura e mineração, aumentaram 9%.

Tabela 1: Evolução do uso da terra na Amazônia Legal entre os anos de 2004 e 2014 (área em milhões de hectares)

Ano	Agricultura		Floresta		Pastagem		Desmatamento		Outros		Total
	Área	$S_{agr}$	Área	$S_{flo}$	Área	$S_{past}$	Área	$S_{des}$	Área	$S_{out}$	
2004	5.32	1.31%	313.09	76.90%	38.47	9.45%	3.009	0.74%	47.27	11.61%	407.16
2008	5.84	1.43%	306.23	75.21%	41.39	10.16%	1.091	0.27%	52.61	12.92%	407.16
2010	5.96	1.46%	305.20	74.96%	42.01	10.32%	0.625	0.15%	53.37	13.11%	407.16
2012	7.03	1.73%	304.30	74.74%	40.30	9.90%	0.418	0.10%	55.13	13.54%	407.16
2014	8.36	2.05%	303.34	74.50%	43.43	10.67%	0.441	0.11%	51.60	12.67%	407.16
Variação	57%		-3%		13%		-85%		9%		

Fonte: Elaboração própria baseado nos dados do TerraClass-INPE e PAM-IBGE, para os anos de 2004, 2008, 2010, 2012 e 2014.

A distribuição dos diferentes usos da terra no território da Amazônia Legal considerado nesse estudo (407 milhões de hectares) variam significativamente ao longo dos anos. Por exemplo, em 2004, 1,3% do total das áreas foram destinadas a agricultura, já em 2014, esse valor foi de 2,05%. Em relação as florestas, 76,9% da região era composta por vegetação natural em 2004, já em 2014, a proporção caiu para 74,5%. A pastagem aumentou de 9,45% em 2004 para 10,67% em 2014. As áreas desmatadas, que em 2004 equivaliam a 0,74% de toda a região, em 2014 caiu para 0,11%. Por tanto, diante das mudanças significativas no padrão do uso da terra e dadas os impactos ambientais e socioeconômicos de tal mudança, torna-se importante investigar a relação de variáveis ambientais e econômicas nesse processo de conversão.

### 3 Referencial teórico

A teoria clássica do século XIX explica as mudanças no uso da terra pela diferença nas rendas relativas de usos alternativos do solo. Estas rendas variam de acordo com as características da terra, em particular a fertilidade (Ricardo, 1817) e a localização (Von Thünen, 1966). A maioria dos estudos economicos na literatura baseia-se nessas teorias e, portanto, examinam a relação entre as escolhas de uso do solo e variáveis como o aluguel fundiário, a qualidade da terra e a distância das cidades (Charir e Parent, 2009). No entanto, diversos outros fatores influenciam nesse processo como as condições climáticas (precipitação e temperatura), os fatores pedológicos (relevo e qualidade do solo), fatores socioeconômicos (preço e disponibilidade dos insumos e tecnologia, facilidade de escoamento da produção), dentre outros.

O modelo teórico utilizado nessa pesquisa segue o adotado por Gallo et al. (2013)<sup>5</sup>. O modelo assume que a terra possui uma qualidade uniforme cuja alocação ótima deriva de um problema de maximização de lucro: o proprietário maximiza os rendimentos líquidos esperados, atualizados ao valor presente, para cada uso alternativo. Considerando que os proprietários de terra possuem expectativas estáticas em relação aos rendimentos líquidos futuros, que as terras estão inicialmente sem produção e que o horizonte temporal é

<sup>5</sup> Uma ampla literatura analisa a base teórica para modelos empíricos de uso da terra: Lichtenberg (1989), Stavins e Jaffe (1990), Wu e Segerson (1995) e Plantinga (1996) e Miller e Plantinga (1999)

infinitamente longo. A decisão de alocação da terra se limita a comparação do valor presente, descontado dos retornos líquidos, para cada uso.

Ou seja, uma quantidade específica de terra será alocada para um determinado uso, somente se o seu valor atual com desconto de rendimentos líquidos estiver acima do valor de todos os outros usos. Na pesquisa em questão, é permitida a locação entre cinco diferentes usos da terra: agricultura, pecuária, floresta, desmatamento e outros usos. A alocação ocorre a nível municipal, para a região da Amazônia Legal. Portanto, as parcelas são definidas como a porcentagem da área total do município dedicada a usos específicos (“share”). Formalmente, a proporção observada do uso da terra  $k$  ( $\forall k = 1, \dots, K$ ), no município  $i$  ( $\forall i = 1, \dots, I$ ), no tempo  $t$  ( $\forall t = 1, \dots, T$ ) é expressa como:

$$S_{kit} = P_{kit} + \varepsilon_{kit} \quad (1)$$

Onde o  $S_{kit}$  é a proporção (“share”) observada de terra atribuída ao uso  $k$  no município  $i$  no tempo  $t$ ;  $P_{kit}$  é a quantidade esperada de terras alocadas para o uso  $k$  no município  $i$  no tempo  $t$ . A proporção de terra observada no tempo  $t$  pode diferir da alocação ótima devido a fatores aleatórios,  $\varepsilon_{kit}$ , como mau tempo ou mudanças de preços imprevistas. Esses eventos aleatórios são assumidos como possuindo média zero (Gallo et al. 2013).

Como em Gallo et al. (2013), para a função da quantidade de terras esperada, é assumido uma especificação logística uma vez que a mesma garante que a função fique dentro do intervalo entre zero e um e que os parâmetros permaneçam parcimoniosos. Além disso, a transformação log-linear é empiricamente atraente. As funções de quantidade de terras esperada são as seguintes:

$$P_{kit} = \frac{e^{\beta'_k X_{kit}}}{\sum_{j=1}^K e^{\beta'_j X_{kit}}} \quad (2)$$

Onde  $X_{kit}$  são as variáveis explicativas relativas ao uso da terra  $k$  ( $\forall k = 1, \dots, K$ ) no município  $i$  ( $\forall i = 1, \dots, I$ ), no tempo  $t$  ( $\forall t = 1, \dots, T$ ) e  $\beta'_k$  é um vetor de parâmetros desconhecidos que mede o efeito de variáveis explicativas nas parcelas de terras esperadas. O modelo teórico implica que as variáveis explicativas  $X_{kit}$  devem incluir o retorno líquido para cada uso da terra (Gallo et al. 2013). As proxies utilizadas nesse estudo serão detalhadas a diante.

Finalmente, o logaritmo natural de cada parcela da terra observada, normalizada de acordo com um uso da terra comum ( $S_{Kit}$ ) é igual a:

$$\tilde{y}_{kit} = \ln(S_{kit}/S_{Kit}) = \beta'_k X_{kit} + u_{kit} \quad (3)$$

Onde  $u_{kit}$  é o termo de erro transformado. Nesse estudo considerou-se cinco usos da terra ( $K=5$ ): agricultura (agr), floresta (flo), pastagem (past), área desmatada (des) e outros usos (out). A soma das parcelas  $S_{agr}$ ,  $S_{flo}$ ,  $S_{past}$ ,  $S_{des}$  e  $S_{out}$  totalizam a área do município. A categoria "outros usos" (out) foi utilizada como referência para a construção das variáveis dependentes:  $\ln(S_{agr}/S_{out})$ ,  $\ln(S_{flo}/S_{out})$ ,  $\ln(S_{past}/S_{out})$ ,  $\ln(S_{des}/S_{out})$ .

## 4 Metodologia

Existe uma variedade de abordagens empíricas de modelagem que se distinguem, basicamente, pelo foco da pesquisa. São dois os principais focos: identificação das causas específicas do processo de mudança do uso da terra e previsão das mudanças nos padrões de uso (Irwin et al., 2014). Os modelos econométricos se tornam úteis na investigação das seguintes questões, de acordo com Turner et al. (2007): identificar os principais impulsionadores do LUC; prever o LUC esperada em resposta a mudanças projetadas nas condições econômicas ou climáticas; e estudar os efeitos das políticas públicas (impostos, subsídios) sobre o LUC.

Como observado por Jean-Sauveur et al. (2014), a escolha da especificação apropriada para um modelo econométrico de uso da terra depende do objetivo da pesquisa, dos tipos de dados disponíveis e da qualidade dos mesmos<sup>6</sup>. De acordo com a seção anterior, o modelo teórico utilizado envolve quatro equações, uma para cada uso da terra, em cinco períodos diferentes no tempo e 475 municípios da Amazônia Legal, por tanto, os dados encontram-se na forma de painel.

De acordo com Anselin e Bera (1998), a autocorrelação espacial pode ser definida como a coincidência de similaridade de valores com a similaridade de localização, ou seja, a autocorrelação espacial expressa a dependência entre observações geográficas. Há autocorrelação espacial positiva quando valores semelhantes (altos ou baixos) de uma variável forem agrupados sobre o espaço. Em contrapartida, há autocorrelação negativa quando na região, os vizinhos, apresentarem valores muito diferentes.

Segundo Verburg et al. (2004), os padrões de uso da terra quase sempre exibem autocorrelação espacial. A explicação para esta autocorrelação pode ser encontrada, em grande parte, nas características ambientais determinantes ao padrão de uso da terra, que são semelhantes no espaço, promovendo a formação de cluster. Outra razão para os padrões espacialmente autocorrelacionados são as interações estratégicas entre os tipos de uso da terra em si. Um exemplo está no fato da expansão urbana geralmente se situar ao lado das áreas urbanas já existentes.

Outras fontes possíveis de autocorrelação espacial, segundo Jean-Sauveur et al. (2014) seriam os erros de medição ou a incompatibilidade de escala dos dados utilizados, além das variáveis latentes não observáveis que podem estar espacialmente correlacionadas. Tais variáveis omitidas poderiam explicar características regionais bioclimáticas específicas que estão correlacionadas no espaço, como por exemplo, a produção de cereais que se concentram nas planícies. A omissão dos efeitos espaciais pode resultar em estimativas de parâmetros tendenciosas e/ou ineficientes e inferência estatística não confiável (Anselin, 2003).

Como nesse estudo foram compatibilizados dados de monitoramento remoto de uso da terra com dados de pesquisa agropecuária é esperado autocorrelação espacial proveniente dos desajustes de diferentes bases de dados. Além disso, é esperado autocorrelação espacial proveniente de erros de medição, uma vez que os dados de monitoramento remoto apresentam imprecisões causadas por fatores exógenos como a presença de nuvens e a incapacidade de interpretação das imagens.

Segundo Anselin (2010), existem diversas maneiras de lidar com a autocorrelação espacial. Para esse trabalho, optou-se por modelá-la através dos termos de erro, assim como em Gallo et al. (2013). Decidiu-se pelo modelo de erro espacial Método Generalizado de

---

<sup>6</sup> Para uma discussão mais detalhada sobre os diferentes tipos de especificação econométrica e uma revisão empírica dos diferentes métodos de modelagem do uso da terra, consultar Irwin e Geoghegan (2001); Plantinga e Irwin (2006); Irwin (2010), Gallo et al. (2013), Gallo et al. (2014)

Momentos (GMM), proposto por Kelejian e Prucha (1999), e pelo modelo de erro proposto por Kapoor et al. (2007) que controla a heterogeneidade não observada.

Por tanto, foram empregados dois modelos empíricos que controlem a autocorrelação espacial e outros dois modelos sem componentes espaciais, a fim de responder ao objetivo secundário, que é analisar se a incorporação da dependência espacial na modelagem acarreta em melhorias nas estimações. Resumidamente, os modelos empregados seguem abaixo:

- I. MQO (Mínimo Quadrado Ordinário, agrupado por equação): ignora heterogeneidade individual, correlação espacial e correlação entre as equações. Como o sistema estimado de equações contém as mesmas variáveis explicativas em cada equação, o estimador MQO agrupado é equivalente ao estimador SUR-MQG, que ignora a heterogeneidade individual e a correlação espacial, mas leva em consideração a correlação entre as equações.
- II. SEM-GMM (Modelo de erro espacial - Método Generalizado de Momentos): proposto por Kelejian e Prucha (1999), leva em consideração a autocorrelação do erro espacial autorregressivo para cada equação, mas ignora a heterogeneidade individual e a correlação entre as equações. Para cada equação, as observações no tempo e no espaço são agrupadas e  $(I_T \otimes W)$  é usada como matriz de peso
- III. MQG-RE (Mínimos Quadrados Generalizados – Efeito Aleatório): modelo de dados de painel padrão com efeitos aleatórios. Esse estimador explica os efeitos individuais aleatórios, mas não leva em conta a autocorrelação espacial e a correlação entre as equações.
- IV. KKP- GMM (Método Generalizado de Momentos ): proposta por Kapoor et al. (2007), leva em consideração a heterogeneidade individual aleatória e a correlação espacial, mas ignora a correlação entre as equações.

Kapoor et al. (2007) consideram um modelo de regressão linear com dados em painel que permite erros correlacionados ao longo do tempo e em unidades espaciais. Em cada período de tempo  $t = 1, \dots, T$  os dados são gerados de acordo com o seguinte modelo:

$$y_n(t) = X_n(t)\beta + u_n(t) \quad (4)$$

onde  $y_n(t)$  é o vetor de observação da variável dependente no período t,  $X_n(t)$  é a matriz de observações dos regressores exógenos no período t (que pode conter o termo constante),  $\beta$  é o vetor dos parâmetros de regressão e  $u_n(t)$  é o vetor do termo de erro.

A abordagem de modelagem do termo de erro seguiu Cliff e Ord (1973, 1981) onde um processo autorregressivo espacial da primeira ordem é considerado:

$$u_n(t) = \rho W_N u_N(t) + \varepsilon_N(t) \quad (5)$$

onde  $W_N$  é uma matriz de ponderação das constantes que não envolvem t,  $\rho$  é um parâmetro escalar autorregressivo e  $\varepsilon_N(t)$  é um vetor de inovações no período t. Por razões de generalidade, permite-se que os elementos de  $y_n(t)$ ,  $X_n(t)$ ,  $u_n(t)$ ,  $\varepsilon_N(t)$  e  $W_N$  dependam de N. Segue as equações (4) e (5) empilhadas:

$$y_n = X_N \beta + u_N \quad (6)$$

$$u_N = \rho (I_T \otimes W_N) u_N + \varepsilon_N \quad (7)$$

Onde  $y_N = [y'_N(1), \dots, y'_N(T)]'$ ,  $X_N = [X'_N(1), \dots, X'_N(T)]'$ ,  $u_N = [u'_N(1), \dots, u'_N(T)]'$  e  $\varepsilon_N = [\varepsilon'_N(1), \dots, \varepsilon'_N(T)]'$ . Para permitir que  $\varepsilon_N$  seja correlacionado no tempo, assume-se a seguinte estrutura de componente de erro para o vetor que  $\varepsilon_N$ :

$$\varepsilon_N = (e_T \otimes I_N) \mu_N + v_N \quad (8)$$

onde  $\mu_N$  é o vetor de especificações de corte transversal,  $v_N$  um vetor de inovações que variam tanto em unidades de seção transversal quanto em períodos de tempo,  $e_T$  é um vetor único e  $I_N$  é a identidade da matriz. Sob a hipótese do efeito aleatória de que os efeitos individuais são independentes no modelo regredido, pode-se reescrever a Equação 7 como:

$$u_N = [I_T \otimes (I_N - \rho W_N)^{-1}] \varepsilon_N \quad (9)$$

Nesse caso, a matriz de variância-covariância de  $u_N$  é:

$$\Omega_u = [I_T \otimes (I_N - \rho W_N)^{-1}] \Omega_\varepsilon [I_T \otimes (I_N - \rho W_N^T)^{-1}] \quad (10)$$

As matrizes de variância de um modelo simples de painel e do modelo apresentado acima, diferem significativamente. A matriz de variância de um modelo simples é mais complicada, e, portanto, o cálculo da inversa é mais difícil. Para o presente trabalho, foi implementado a especificação no termo de erro por meio de estimativa de máxima verossimilhança dos modelos aleatório. O estimador  $\beta$  por Mínimos Quadrados Generalizados (MQG) é dado por:

$$\begin{aligned} \hat{\beta}_{MQG,N} &= \{X'_N [\Omega_{u,N}^{-1}(\rho, \sigma_v^2, \sigma_1^2)] X_N\}^{-1} X'_N [\Omega_{u,N}^{-1}(\rho, \sigma_v^2, \sigma_1^2)] y_N \\ &= \{X_N^*(\rho)' [\Omega_{\varepsilon,N}^{-1}(\sigma_v^2, \sigma_1^2)] X_N^*(\rho)\}^{-1} X_N^*(\rho)' [\Omega_{\varepsilon,N}^{-1}(\sigma_v^2, \sigma_1^2)] y_N^*(\rho) \end{aligned} \quad (11)$$

Onde:

$$\begin{aligned} y_N^*(\rho) &= [I_T \otimes (I_N - \rho W_N)] y_N \\ X_N^*(\rho) &= [I_T \otimes (I_N - \rho W_N)] X_N \end{aligned} \quad (12)$$

Nessa etapa a dependência explícita ( $\Omega_{u,N}^{-1}$  e  $\Omega_{\varepsilon,N}^{-1}$ ) é denotada em  $\rho$  e/ou  $\sigma_v^2$  e  $\sigma_1^2$ . As variáveis  $y_N^*(\rho)$  e  $X_N^*(\rho)$  podem ser vistas como os resultados de uma transformação espacial do tipo Cochrane-Orcutt do modelo original. Mais especificamente, pela multiplicação de (6) e (7) com os rendimentos  $[I_T \otimes (I_N - \rho W_N)]$ :

$$y_N^*(\rho) = X_N^*(\rho) \beta + \varepsilon_N \quad (13)$$

Kapoor et al. (2007), guiados pela literatura clássica do componente de erro, observaram que uma maneira conveniente de calcular o estimador  $\hat{\beta}_{MQG,N}$  seria transformando a equação (13) por meio da multiplicação por  $\Omega_{\varepsilon,N}^{-1/2}$ :

$$\sigma_v \Omega_{\varepsilon,N}^{-1/2} = I_{NT} - \theta Q_{1,N} \quad (14)$$

Onde  $\theta = 1 - \sigma_v/\sigma_1$ . Dessa forma, tem-se estimadores  $\hat{\beta}_{MQG,N}$  idênticos aos estimadores por Mínimo Quadrado Ordinário (MQO). Como  $\check{\rho}, \check{\sigma}_{v,N}^2, \check{\sigma}_{1,N}^2$  são os estimadores de

$\rho, \sigma_{v,N}^2, \sigma_{1,N}^2$ , o estimador correspondente ao MQG ( $\hat{\beta}_{MQGF,N}$ ) é obtido substituindo  $\rho, \sigma_{v,N}^2, \sigma_{1,N}^2$  pelos estimadores da expressão do MQG:

$$\hat{\beta}_{MQGF,N} = \{X_N^*(\check{\rho}_N)' [\Omega_{\varepsilon,N}^{-1}(\check{\sigma}_{v,N}^2, \check{\sigma}_{1,N}^2)] X_N^*(\check{\rho}_N)\}^{-1} \times X_N^*(\check{\rho}_N)' [\Omega_{\varepsilon,N}^{-1}(\check{\sigma}_{v,N}^2, \check{\sigma}_{1,N}^2)] y_N^*(\check{\rho}_N) \quad (15)$$

Este estimador pode ser utilizado convenientemente como um estimador MQO, após a transformação do modelo de forma análoga ao descrito para o estimador MQG<sup>7</sup>. Por tanto, Kapoor et al. (2007) definem um estimador de mínimos quadrados generalizados factível para os parâmetros de regressão do modelo. Este estimador é baseado em uma transformação espacial Cochrane-Orcutt, assim como em transformações utilizadas na estimativa de modelos clássicos de componentes de erros. Os autores demonstram que os estimadores MQG e MQGF possuem a mesma distribuição.

#### 4.1 Matriz de vizinhança e testes de dependência espacial

A matriz de pesos espacial escolhida baseia-se em considerações puramente geográficas. Optou-se pela matriz de contiguidade proposta por Baumont (2004), na qual a matriz de vizinhança é construída por meio do método dos  $k$  vizinhos mais próximos, definida da seguinte forma:

$$\begin{cases} w_{ij}(k) = 0, \text{ se } i = j, \forall k \\ w_{ij}(k) = 1, \text{ se } d_{ij} \leq d_i(k) \\ w_{ij}(k) = 0, \text{ se } d_{ij} > d_i(k) \end{cases} \quad \text{e} \quad w_{ij}(k) = w_{ij}(k) / \sum_j w_{ij}(k)$$

Onde  $w_{ij}(k)$  é um elemento da matriz normalizada,  $d_{ij}$  é uma distância definida para cada unidade  $i$ , ou seja,  $d_{ij}$  é a menor distância entre a região  $i$  e todas as outras unidades de modo que cada unidade  $i$  possui exatamente  $k$  vizinhos. Optou-se por  $k = 6$  vizinhos.

Após a construção da matriz de peso, estatísticas para testes de dependência espacial foram empregadas. A estatística  $I$  de Moran foram aplicadas diretamente sobre as variáveis  $A_{kit}/S_{kit}$ , onde  $A_{kit}$  é a área total do uso da terra  $k$ , no município  $i$ , no tempo  $t$ ; e  $S_{kit}$  é a proporção observada do uso da terra  $k$ . Todos os testes apresentaram valores de  $I \text{ Moran} > 0,32$ , indicando autocorrelação espacial.

O teste condicional de Baltagi et al. (2003) para correlação do erro espacial e para efeitos aleatórios em modelos de painel também foram aplicados. Todos os testes rejeitaram a hipótese nula de não existir correlação espacial no erro e de que a estimação por efeitos fixos seria preferível. Por tanto, por meio dos testes, confirma-se a dependência espacial do modelo, a autocorrelação do erro e a adequação da estimação por efeitos aleatórios.

<sup>7</sup> A consistência e normalidade assintótica dos estimadores MQG podem ser encontrados em Kapoor et al. (2007)

## 5 Base de dados e descrição das variáveis

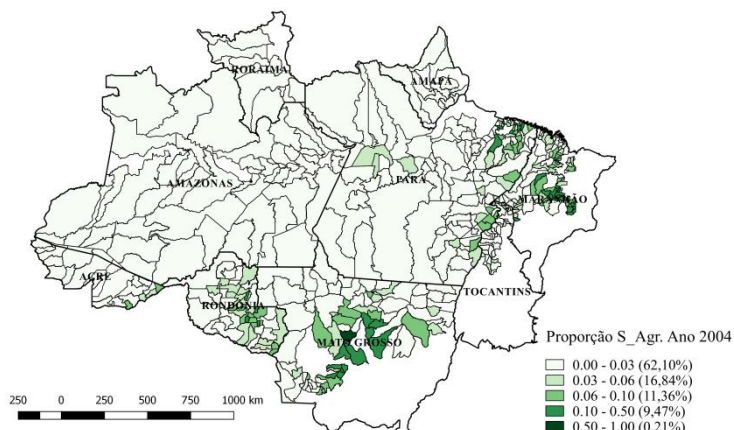
### 5.1 Descrição das variáveis dependentes

Os dados sobre o uso da terra dos municípios da Amazônia Legal foram extraídos do projeto TerraClass. O projeto monitora o uso da terra da região desde 2004 e possuem os dados de satélite de cinco anos (2004, 2008, 2010, 2012 e 2014). O mapeamento considera 12 diferentes classes de terras cujas descrições seguem no Anexo A. O mapa final do TerraClass combina os dados regionais do PRODES de áreas de floresta, áreas de não floresta e corpos d'água (Almeida et.al, 2016). Assim como Carvalho (2014), optou-se por desconsiderar as áreas não floresta dessa pesquisa, pois se trata de área sem mapeamento de uso e cobertura. As demais classes de terras foram agregadas de acordo com a necessidade da pesquisa.

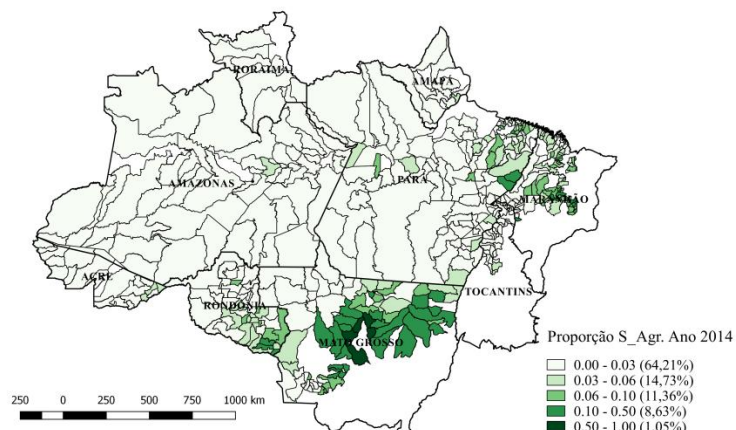
Os diferentes tipos de pastagens (classes 6, 7, 8 e 9) foram agregados em uma única classe e classificados como “Pastagem”. As áreas de “Floresta” e “Desmatadas” foram mantidas as mesmas do PRODES. As classes “Outros”, “Mineração”, “Hidrografia”, “Vegetação secundária” e “Área urbana” foram agregadas e classificadas como “Outros”. Por fim, para a classe de “Agricultura anual”, foi necessário considerar outra fonte de dados, uma vez que as informações do TerraClass, para esse uso da terra em específico, apresentavam informações discrepantes as divulgadas pelos órgãos oficiais. Por tanto, optou-se por utilizar os dados de área plantada de lavoura permanente e temporária da Produção Agrícola Municipal (PAM), divulgadas pelo IBGE.

Ainda no tratamento da base de dados do TerraClass, foi eliminado da pesquisa aqueles municípios com mais de 50% de “Área não observada” e com valores de rendimento da pastagem muito acima do esperado (as variáveis explicativas serão detalhadas a diante). Dessa forma, de 771 municípios da Amazônia Legal, 475 foram utilizados na pesquisa, o que equivale a 407 milhões de hectares, distribuídos em cinco classes de terras, como apresentado na Tabela 1. As áreas de uso da terra são utilizadas na construção das variáveis dependentes ( $\ln(S_{agr}/S_{out})$ ,  $\ln(S_{flo}/S_{out})$ ,  $\ln(S_{past}/S_{out})$ ,  $\ln(S_{des}/S_{out})$ ). As Figuras 1 e 2 exibem os mapas das proporções de cada categoria ( $S_{agr}$ ,  $S_{flo}$ ,  $S_{past}$ ,  $S_{des}$ ), para os anos de 2004 e 2014.

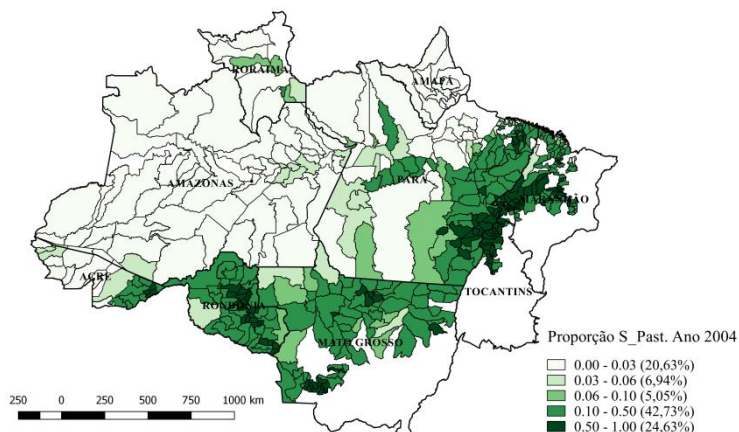
### Amazônia Legal



### Amazônia Legal



### Amazônia Legal



### Amazônia Legal

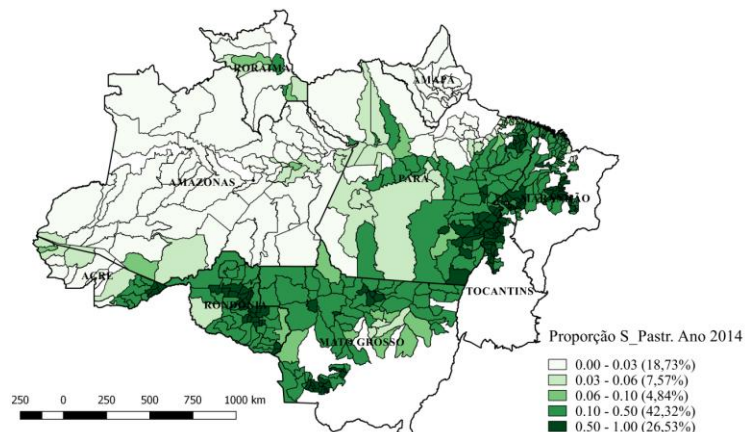
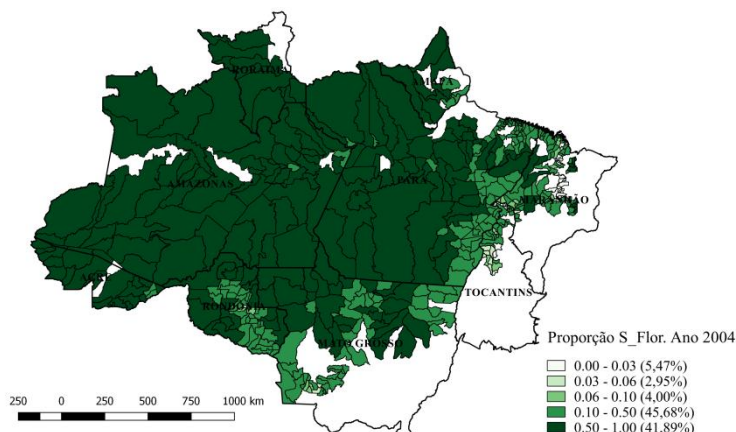


Figura 1: Mapas das distribuições das proporções da terra de uso Agrícola e Pastagem para os anos de 2004 e 2014.

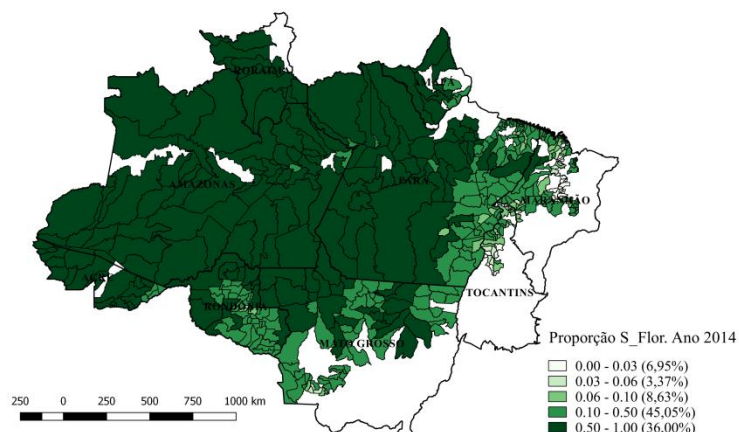
Fonte: Elaboração própria com base nos dados do TerraClass – INPE

De acordo com a Figura 1, em 2004, cerca de 62,1% dos 475 municípios analisados possuem entre zero e 3% de suas áreas destinadas a agricultura e somente 0,2% dos municípios apresentam mais de 50% de área agrícola. Em 2014 cresceu o número de município com até 3% de área agrícola e com mais de 50% de plantações, aproximadamente 64,2% e 1,05% respectivamente. Esse percentual equivale a 9 municípios a mais com até 3% de suas áreas destinadas a agricultura e um acréscimo de 4 municípios com mais de 50% de áreas agrícolas. Em relação às pastagens, observa-se que em 2004 aproximadamente 42,7% dos municípios possuíam entre 10% e 50% de suas áreas destinadas a pastagem e cerca de 24,6% apresentavam mais de 50% de pastagem. Tal configuração modificou-se em 2014 onde cerca de 26,5% dos municípios possuíam mais de 50% de suas áreas destinadas a pastagem, o que equivale a um acréscimo de 9 municípios. É interessante observar que em 2004 cerca de 20,6% dos município apresentavam não mais que 3% de pastagem já em 2014 esse percentual caiu para 18,73%, indicando que 9 município passaram a apresentar mais que 3% de áreas de pastagens em um intervalo de 10 anos. O que indica que as pastagens cresceram de forma relativamente abrupta e rápida nesse intervalo de tempo.

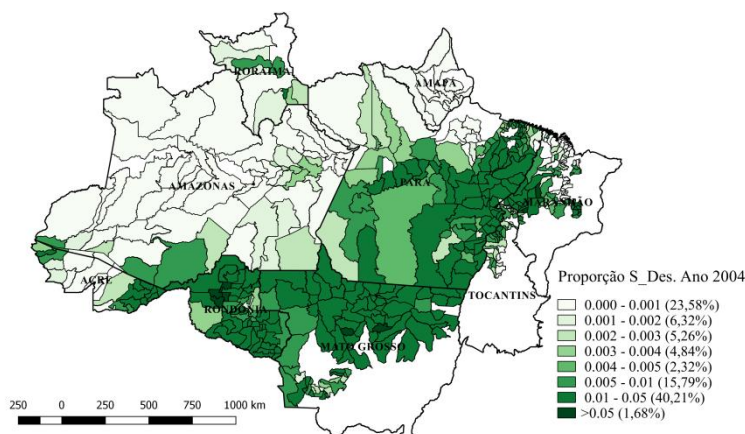
### Amazônia Legal



### Amazônia Legal



### Amazônia Legal



### Amazônia Legal

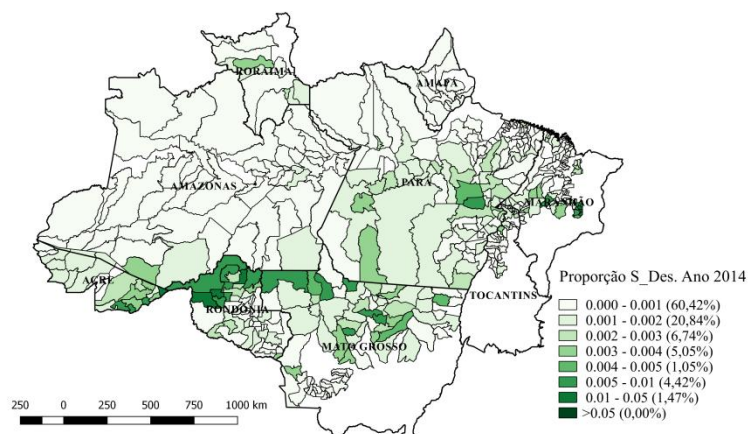


Figura 2: Mapas das distribuições das proporções da terra de uso Floresta e Desmatamento, para os anos de 2004 e 2014.

Fonte: Elaboração própria com base nos dados do TerraClass - INPE

Na Figura 2 observa-se os mapas das distribuições de floresta e de desmatamento nos municípios analisados, nos anos de 2004 e 2014. Como era de se esperar, um grande número de municípios possuíam mais de 10% de suas áreas compostas por florestas, em 2004. Aproximadamente 45,7% dos municípios possuíam entre 10% e 50% de floresta e cerca de 41,9% apresentavam mais de 50%. O interessante é observar a diminuição de municípios com mais de 50% de área florestal em 2014, somente 36%. Isso indica que 27 municípios tiveram suas áreas de florestas reduzidas abruptamente visto que em 2004, 4% dos municípios possuíam entre 6% e 10% de floresta, já em 2014 esse percentual aumentou para 8,6%, o que equivale a 21 municípios. Ou seja, houve uma queda de municípios com mais de 50% de área florestal e um aumento de municípios no intervalo entre somente 6%-10% de florestas.

Em relação ao desmatamento, é interessante observar que as áreas desmatadas em cada município diminuíram entre cada ano. Em 2004, cerca de 40,2% dos municípios tiveram entre 1% e 5% de suas áreas desmatadas, já em 2014 somente 1,47%. Ou seja, em 2004, 191 municípios apresentaram desmatamento equivalente a 1%-5% de suas áreas, já em 2014 somente 7 municípios. Além disso, em 2014, cerca de 60,4% dos municípios apresentaram desmatamento entre zero e 0,1%. Esses resultados eram de se esperar visto que a representação do desmatamento não é acumulada e que as leis ambientais, mesmo que pouco fiscalizadas, impedem o crescimento desenfreado do desmatamento. O mais importante nessa análise descritiva é a clara diminuição da floresta na região que é chamada de cinturão do

desmatamento assim como a clara expansão da pastagem e agricultura rumo ao interior da Amazônia Legal.

## 5.2 Descrições das variáveis independentes

Em relação as variáveis explicativas, a literatura sobre a teoria do uso da terra sugere a inclusão do retorno líquido para cada uso e a qualidade do solo. Por tanto, para essa pesquisa, as variáveis exógenas representam os rendimentos dos solos agrícolas ( $R_{agr}$ ), florestais ( $R_{flor}$ ), de pastagem ( $R_{past}$ ) e urbanos ( $R_{urb}$ ), para cada ano (2004, 2008, 2010, 2012 e 2014) e para os 475 municípios da Amazonia Legal considerados.

O rendimento da terra agrícola foi obtido por meio da divisão do total do rendimento agrícola pela área de terras agrícolas, em cada município. O rendimento agrícola nada mais é que a soma do “Valor de Produção da Lavoura Permanente” e “Valor de Produção da Lavoura Temporária”. E as áreas de terras agrícolas a soma da “Área Plantada de Lavoura Permanente” e “Área Plantada de Lavoura Temporária”. Todas essas variáveis foram coletadas da Produção Agrícola Municipal (PAM) – IBGE, para cada ano considerado na pesquisa.

O rendimento das áreas florestais foi obtido por meio da divisão do valor total da produção dos produtos da silvicultura pelas áreas florestais. O valor total da produção dos produtos da silvicultura foi calculado através da soma das seguintes variáveis: “Valor da Produção do Carvão Vegetal”, “Valor da Produção da Lenha” e “Valor da Produção da Madeira em Tora”. Tais variáveis são disponibilizadas anualmente pela Produção da Extração Vegetal e da Silvicultura (PEVS) – IBGE. Os dados de áreas florestais foram os mesmos utilizados para a construção da variável dependente  $S_{flo}$ , retirados da base de dados do TerraClass - INPE.

O rendimento das áreas de pastagens foi calculado por meio da divisão do total de cabeças de gados pela área de pastagem, em cada município. Como não existe dados monetários da rentabilidade da pecuária por município, optou-se pelos dados de tamanho do rebanho como proxy para a rentabilidade, dessa forma, ao invés de termos uma variável com informação do valor monetário de cada hectare (R\$/ha), teremos o tamanho do rebanho por hectare (cabeça/ha). Os dados de tamanho do rebanho em cada município foram extraídos da Produção da Pecuária Municipal (PPM) – IBGE, para cada ano considerado. Os dados de áreas de pastagem foram os mesmos utilizados para a construção da variável dependente  $S_{pas}$ , retirados da base de dados do TerraClass - INPE.

Para o rendimento das áreas urbanas, foi utilizado como proxy a densidade populacional de cada município, nos anos analisados. A escolha de tal proxy está em concordância com a literatura de modelos econométricos de mudança do uso da terra que utilizam medidas de proxy para lucros urbanos. As proxys geralmente utilizadas são a distância para os principais centros urbanos mais próximos, renda per capita dos municípios, preço médio dos terrenos residenciais e a densidade demográfica (Plantinga e Ahn, 2002, Lubowski et al., 2008). As estatísticas descritivas das variáveis dependentes e independentes seguem na Tabela 2.

Tabela 2: Estatística descritiva das variáveis dependentes e independentes

Variável	Descrição	Média	Desvio padrão	Mínimo	Máximo
S_agr	Proporção da terra de uso agrícola	0,041	0,076	0	0,797
S_flor	Proporção da terra de uso florestal	0,414	0,311	0	0,992
S_past	Proporção da terra de uso pastagem	0,290	0,256	0	0,938
S_desmt	Proporção da terra desmatada	0,002	0,005	0	0,092
S_outros	Proporção da terra de outros usos	0,150	0,116	0,005	0,761
R_agr	Rentabilidade da terra agrícola (R\$/ha)	2243,861	1742,322	0	24285,310
R_flor	Rentabilidade da terra floresta (R\$/ha)	134,734	430,698	0	9463,421
R_past	Rentabilidade da terra pastagem (cabeça/ha)	1,484	1,337	0	34,998
R_urb	Rentabilidade da terra urbana (hab/ha)	0,207	0,660	0,001	13,363

Fonte: Resultados da pesquisa

Por fim, como a construção das variáveis explicativas fez uso dos mesmos dados utilizados para a construção das variáveis dependentes, endogeneizando as variáveis explicativas, foi necessário a deflação no tempo. As variáveis dependentes passaram a ser explicadas pelas variáveis independentes do ano anterior. Por exemplo, as variáveis  $\ln(S_{agr}/S_{out})$  de 2008 foram regredidas com as variáveis  $R_{agr}$ ,  $R_{flor}$ ,  $R_{past}$  e  $R_{urb}$  dos anos de 2004. Resolvendo problemas de endogeneidade.

## 6 Resultados

### 6.1 O impacto da renda da terra sobre a mudança do uso do solo

Objetiva-se nesse estudo verificar o impacto do retorno econômico da terra sobre a dinâmica da mudança do uso do solo. Analisando os resultados das estimações por SEM-GMM e KKP-GMM, na Tabela 3, observa-se parâmetros espaciais autorregressivos ( $\rho$ ) positivos e significativos a 0,1% para as quatro equações. O que implica que a alocação do uso da terra é influenciada por fatores não observados nas áreas vizinhas. Como mencionado anteriormente, essas variáveis omitidas podem estar relacionadas com as características regionais climáticas, dentre outros fatores. Em relação a interpretação econômica das estimativas, vale destacar que os resultados aqui apresentados devem ser interpretados com cautela uma vez que as variáveis dependentes estão na forma logarítmica.

Para a primeira equação estimada por SEM-GMM ( $\ln(S_{agr}/S_{out})$ ), os resultados apresentados na Tabela 4 mostram que somente duas estimativas dos parâmetros são significativamente diferentes de zero ao nível de 0,1%. Um aumento da renda agrícola ( $R_{agr}$ ) impacta negativamente a proporção  $S_{agr}/S_{out}$  e a variável de densidade demográfica, proxy para renda urbana ( $R_{urb}$ ), impacta positivamente a proporção  $S_{agr}/S_{out}$ . Um aumento de R\$1,00 na renda da terra agrícola provoca uma diminuição de 0,02% da proporção  $S_{agr}/S_{out}$ . Ou seja, um aumento na rentabilidade da terra agrícola diminui a decisão de alocação de terras entre agricultura ou outros usos. Já um aumento de 1 hab/hac provoca um aumento de 23,8% da proporção  $S_{agr}/S_{out}$ . Ou seja, um aumento demográfico implica que o município tende a ter menos terras agrícolas em relação a outros usos. A mesma equação estimada por KKP-GMM apresentou somente um parâmetro significativo ao nível de 5%, que foi a proxy para renda urbana ( $R_{urb}$ ). Todos os demais, não foram significativos ao nível mínimo de 5%.

Tabela 3: Resultado das estimações

	MQO	SEM-GMM	MQG-RE	KKP-GMM
$\ln(S_{agr}/S_{out})$				
Constante	-1.5530***	-1.6651***	-2.1360***	-0.1135
$R_{agr}$	-0.0003***	-0.0002***	-0.0000*	-0.0000
$R_{past}$	-0.0062	0.0077	-0.0122	-0.0102
$R_{flo}$	0.0000	-0.0000	-0.0000	0.0000
$R_{urb}$	0.3000***	0.2385***	0.4630	0.1647*
$\rho$		0.3944***		0.9581***
$\sigma_{\mu}^2$			4.7600	14.549***
$R^2$	0.0845			
$\bar{R}^2$	0.0825			
$\ln(S_{past}/S_{out})$				
Constante	0.8720***	0.6981***	-0.0817	0.0252
$R_{agr}$	-0.0004***	-0.0003***	-0.0000	-0.0000
$R_{past}$	-0.0349	-0.0323	0.0227	0.0121
$R_{flo}$	-0.0001	-0.0002*	-0.0001	0.0000
$R_{urb}$	-0.0586	-0.1596**	0.2110	-0.0026
$\rho$		0.5421***		0.9938***
$\sigma_{\mu}^2$			15.2900**	14.630***
$R^2$	0.0894			
$\bar{R}^2$	0.0875			
$\ln(S_{flor}/S_{out})$				
Constante	0.264 ***	0.3778***	0.6400***	-0.0222
$R_{agr}$	0.0002***	0.0002***	0.0001***	0.0000
$R_{past}$	0.01870	0.0000	-0.0056	-0.0062
$R_{flo}$	0.0001	0.0002*	0.0000	0.0001
$R_{urb}$	-0.1850***	-0.1857***	-0.0526	-0.0477
$\rho$		0.3668***		0.9692***
$\sigma_{\mu}^2$			26.3600***	11.397***
$R^2$	0.0802			
$\bar{R}^2$	0.0782			
$\ln(S_{des}/S_{out})$				
Constante	-2.6680***	-3.5460***	-2.6450***	-0.4326
$R_{agr}$	-0.0004***	-0.0003***	-0.0004***	-0.0001**
$R_{past}$	-0.0879*	-0.0703*	-0.0801	-0.0196
$R_{flo}$	0.0004**	0.0004***	0.0002	0.0001
$R_{urb}$	-0.0455	0.0932	-0.1090*	0.0871
$\rho$		0.1951***		0.8643***
$\sigma_{\mu}^2$			48.8800***	5.313***
$R^2$	0.1013			
$\bar{R}^2$	0.0994			

Fonte: Resultado da pesquisa.

\*p<0,05; \*\*p<0,01; \*\*\*p<0,001

Os resultados da segunda equação ( $\ln(S_{past}/S_{out})$ ) por SEM-GMM, também apresentados na Tabela 4, mostram três estimativas dos parâmetros significativamente diferentes de zero, aos níveis de significância considerados na pesquisa. Um aumento da renda agrícola ( $R_{agr}$ ) impacta negativamente a proporção  $S_{past}/S_{out}$ . Ou seja, um aumento de R\$1,00 na renda da terra agrícola provoca uma diminuição de 0,03% da proporção  $S_{past}/S_{out}$ . Um aumento na rentabilidade da terra agrícola diminui a decisão de alocação de

terras destinadas a pastagens ou outros usos. Algumas terras de pastagens possuem potencial de conversão em terras agrícolas. Um aumento de rentabilidade de terras agrícolas estimularia o uso de terras de pastagens para agricultura, provocando um processo de *Direct Land Use Change* (LUC).

Já a densidade demográfica ( $R_{urb}$ ) possui sinal do coeficiente negativo. Um aumento populacional de 1 hab/hac provoca uma diminuição de 15,9% da proporção  $S_{past}/S_{out}$ . Espera-se que um aumento da densidade populacional amplie as áreas urbanas, que encontram-se em  $S_{out}$ . Em relação a renda da terra florestal ( $R_{flo}$ ), o sinal do coeficiente é negativo, ou seja, um aumento de R\$1,00 na renda das áreas naturais provocam uma diminuição de 0,02% da proporção  $S_{past}/S_{out}$ . A renda da terra florestal é mais elevada que a renda da pastagem, incentivando o proprietário de terra a converter áreas de pastagem em floresta, visando uma extração futura, caracterizando um *Direct Land Use Change* (LUC). Além disso, uma vez que a classe de terra “Silvicultura” encontra-se em  $S_{out}$ . Um aumento da renda da terra florestal tende a aumentar a extração de madeiras e conseqüentemente as áreas de silvicultura. Os resultados para a mesma equação, estimadas por KKP-GMM não apresentou parâmetros significativos.

Ainda na Tabela 4, estão apresentados os resultados da terceira equação ( $\ln(S_{flor}/S_{out})$ ) por SEM-GMM. Os resultados mostram três estimativas dos parâmetros significativamente diferentes de zero, aos níveis de significância considerados na pesquisa. A renda agrícola ( $R_{agr}$ ) possui sinal do coeficiente positivo, ou seja, um aumento de R\$1,00 na renda da terra agrícola provoca um aumento de 0,02% da proporção  $S_{flor}/S_{out}$ . Ou seja, um aumento na renda da terra agrícola provoca um aumento na decisão de alocação entre terras florestais ou de outros usos. Com terras agrícolas gerando maiores rendimentos, espera-se uma maior exploração das terras naturais visando o aumento de áreas disponíveis para a agricultura.

A densidade demográfica ( $R_{urb}$ ) possui sinal do coeficiente negativo, ou seja, um aumento populacional tende a aumentar as áreas urbanas, que encontram-se em  $S_{out}$ . Já a renda da terra florestal ( $R_{flo}$ ) apresentou um sinal do coeficiente positivo, ou seja, um aumento de R\$ 1,00 na renda das áreas naturais provocam um aumento de 0,02% da proporção  $S_{flor}/S_{out}$ . Esse resultado somente pode ser explicado por um processo de especulação da terra. Com terras naturais gerando maior rentabilidade, a tendência é que ocorra um processo de reflorestamento com o objetivo de aumentar a exploração, posteriormente. Ou ainda diminuir as áreas de silvicultura ( $S_{out}$ ), para incentivar a valorização da terra natural. Os resultados para a mesma equação ( $\ln(S_{flor}/S_{out})$ ), estimadas por KKP-GMM não apresentou parâmetros significativos.

Por fim, os resultados da quarta e última equação ( $\ln(S_{des}/S_{out})$ ) por SEM-GMM mostram três estimativas dos parâmetros significativamente diferentes de zero, aos níveis de significância considerados na pesquisa. Essa equação relaciona a proporção de áreas desmatadas da Amazônia Legal com as variáveis econômicas de rentabilidade da terra. Diferentemente das demais equações, a densidade demográfica ( $R_{urb}$ ) não mostrou-se significativa, o que é contraditório aos estudos que consideram o aumento populacional uma das causas do desmatamento na Amazônia (PFAFF, 1999; IGLIORI, 2008). Já a renda agrícola ( $R_{agr}$ ) possui sinal do coeficiente negativo, ou seja, um aumento de R\$ 1,00 da renda da terra agrícola provoca uma diminuição de 0,03% da proporção  $S_{des}/S_{out}$ . Ou seja, um aumento na renda da terra agrícola provoca uma diminuição na decisão de alocação entre terras desmatadas ou de outros usos.

A renda de pastagem ( $R_{past}$ ) possui sinal do coeficiente negativo, ou seja, um aumento de 1 cabeça/hac da renda da terra destinada a pastagem provoca uma diminuição de 7,03% da proporção  $S_{des}/S_{out}$ . Por fim, a renda da terra florestal ( $R_{flo}$ ) apresentou sinal do coeficiente positivo, ou seja, um aumento de R\$1,00 na renda das áreas naturais provocam um aumento de 0,04% da proporção  $S_{des}/S_{out}$ . Com a exploração florestal mais rentável, espera-se um incentivo ao desmatamento.

## 6.2 Melhorias preditivas nas estimações

O objetivo secundário dessa pesquisa foi verificar o quanto a incorporação da dimensão espacial no modelo econométrico provoca melhorias preditivas nas estimações. Como as estimações são diferentes, distintos resíduos são gerados e conseqüentemente diferentes previsões. Para avaliar a exatidão dos diferentes modelos preditivos, foi calculado a raiz da média do quadrado dos resíduos (Root mean squared error – RMSE em ingles) para cada modelo. Os resultados seguem na Tabela 3.

Tabela 4: Resultados RMSE

	MQO	SEM-GMM	MQG-RE	KKP-GMM
$\ln(S_{agr}/S_{out})$	1.853	1.856	0.992	1.833
$\ln(S_{past}/S_{out})$	2.045	2.052	0.938	2.053
$\ln(S_{flor}/S_{out})$	1.571	1.574	0.890	1.560
$\ln(S_{des}/S_{out})$	2.157	2.053	1.943	2.134

Fonte: Resultados da pesquisa

Quanto menor o valor do RMSE, mais preciso é o modelo. O impacto da autocorrelação espacial na precisão pode ser avaliado comparando as colunas 1 (MQO) e 2 (SEM-GMM), pois são modelos simples sem heterogeneidade individual. Observa-se valores ligeiramente maiores para o modelo SEM-GMM. Quando a heterogeneidade individual é levada em consideração (MQG-RE e KKP-GMM), a autocorrelação espacial parece também não melhorar as previsões. O impacto isolado da heterogeneidade individual no poder preditivo dos modelos pode ser avaliada comparando colunas 1 (MQO) e 3 (MQG-RE), por um lado, e as colunas 2 (SEM-GMM) e 4 (KKP-GMM) por outro lado. Os resultados indicam que ao levar em consideração a heterogeneidade individual ocorre uma melhora significativamente nas previsões, principalmente nos modelos em que a autocorrelação espacial não está presente.

## 7 Conclusão

Considerações econômicas importantes podem ser extraídas dos resultados. De modo geral, a renda da terra agrícola parece impactar na mudança do uso da terra significativamente. Um aumento na rentabilidade dessa terra pode provocar uma diminuição das áreas agrícolas, por meio de um processo especulativo; uma diminuição das áreas de pastagens, estimulado por um processo de *Direct Land Use Change* (LUC); um aumento de áreas florestais, dado a menor necessidade de exploração de terras naturais; e por fim, uma diminuição das áreas desmatadas.

A densidade populacional parece impactar significativamente em quase todos os processos de mudança do uso da terra. Um aumento populacional pode aumentar as áreas urbanas e/ou diminuir as áreas de pastagem e florestal, em prol de um aumento das áreas agrícolas, dada a maior necessidade de produção de alimentos, o que caracterizaria um

processo de *Direct Land Use Change* (LUC) e *Indirect Land Use Change* (ILUC). No entanto, a densidade populacional parece não impactar no processo de desmatamento.

A renda da terra florestal parece impactar na mudança das terras de pastagem, floresta e áreas desmatadas. Um aumento nessa renda diminui as áreas de pastagem por meio do incentivo a exploração vegetal, provocando um *Direct Land Use Change* (LUC); diminui as áreas de floresta, também pelo mesmo incentivo à exploração vegetal e consequentemente, aumenta as áreas desmatadas. Por fim, a renda da terra de pastagem parece impactar somente na mudança de uso da terra desmatada. Um aumento dessa renda diminui as áreas desmatadas, o que pode ser explicado pelo aumento da produtividade dessa terra, tornando desnecessário converter áreas naturais em pastagens, diminuindo o desmatamento.

O objetivo secundário dessa pesquisa foi verificar o quanto a incorporação da dimensão espacial no modelo econométrico provoca melhorias preditivas nas estimações. A princípio, as estimações por SEM-GMM e KKP-GMM, considerando a autocorrelação espacial, não pareceram melhorar a precisão das estimações. Em contrapartida, os modelos que levam em consideração a heterogeneidade individual, MQG-RE e KKP-GMM, parecem melhorar significativamente o poder preditivo das estimações.

Consequentemente, as estimações resultaram em poucos parâmetros significativamente diferentes de zero, aos níveis de significância considerados na pesquisa. A falta de significância dos coeficientes pode ser explicada pelas escolhas das variáveis independentes utilizadas. Segundo Verburg et al. (2004) é importante modelar a mudança do uso da terra por meio de variáveis que representem as "forças motrizes" do processo, que seriam não somente as variáveis socioeconômicas e biofísicas, mas também de manejo de terras. Essas forças motrizes são frequentemente consideradas exógenas ao sistema de uso da terra para facilitar a modelagem. No entanto, em alguns casos, esta suposição dificulta a descrição adequada do sistema de uso da terra, uma vez que as decisões de alocação são determinadas conjuntamente.

Segundo Chakir e Parent (2009) a variável da inclinação seria importante no processo de alocação, sugerindo que as terras com uma inclinação íngreme são mais frequentemente dedicadas à floresta. Além disso, diversas literaturas mostram a importância de se considerar a qualidade do solo em estudos cujo objetivo é explicar a mudança no uso da terra (Wu e Segerson, 1995). No entanto, como observado por Bell et al. (2006) é problemático medir a qualidade da terra dado a falta de proxies adequadas. Além disso, no Brasil, dados de uso do solo e pedologia são escassos e de difícil acesso, além de não possuírem um acompanhamento temporal. Jean-Sauveur et al. (2014) considera que modelar o uso de terra no curto prazo também diminui fortemente a significância dos coeficientes ou até mesmo os torna insignificantes ou com sinal contra intuitivo.

Todos esses fatores não considerados e modelados nessa pesquisa podem ter influenciado na falta de significância dos parâmetros e se tornam sugestões de melhorias em trabalhos futuros.

## REFERÊNCIAS

- ALMEIDA, C., A., et al. High spatial resolution land use and land cover mapping of the Brazilian Legal Amazon in 2008 using Landsat-5/TM and MODIS data. *Acta Amaz.*, Manaus, v. 46, n. 3, p. 291-302, 2016.
- ANSELIN, L. *Spatial Econometrics : Methods and Models*. Kluwer Academic Publishers, Dordrecht, 1988.
- ANSELIN, L. Spatial econometrics in RSUE: Retrospect and prospect. *Regional Science and Urban Economics* 37: 450–456, 2007.
- ANSELIN, L. Thirty years of spatial econometrics. *Papers in Regional Science* 89: 3–25, 2010.
- AGUIAR, A.P.; CÂMARA, G.; ESCADA, M.I.S. Spatial statistical analysis of land-use determinants in the Brazilian Amazonia: Exploring intra-regional heterogeneity. *Ecological Modelling*, vol. 209, p.169-188, 2007.
- ANDERSEN, L. E.; GRANGER, C. W. J.; REIS, E. J.; WEINHOLD, D.; WUNDER, S. The Dynamics of Deforestation and Economic Growth in the Brazilian Amazon. *United Kingdom: Cambridge University Press*, 2002.
- ARIMA, E. Y.; RICHARDS, P.; WALKER, R.; CALDAS, M. M. Statistical confirmation of indirect land use change in the Brazilian Amazon. *Environmental Research Letters*, vol. 6, p. 1-7, 2011.
- ARAUJO, C.; BONJEAN, C. A.; COMBES, J. L.; MOTEL, P. C.; REIS, J. E. Property Rights and Deforestation in the Brazilian Amazon. *Ecological Economics*, vol. 68, p. 2461-2468, 2009.
- BAUMONT, C. Spatial effects in housing price models. Do housing prices capitalize urban development policies in the agglomeration of Dijon (1999)? LEG - *Document de travail - Economie 2004-04*, LEG, Laboratoire d'Economie et de Gestion, CNRS UMR 5118, Université de Bourgogne, 2004.
- BALTAGI, B. H.; SONG, S. H.; KOH, W. Testing Panel Data Regression Models with Spatial Error Correlation. *Journal of Econometrics*, 117, 123–150, 2003.
- BATEMAN, I. J., et al. Bringing ecosystem services into economic decision-making: *Land use in the United Kingdom*. *Science* 341: 45–50, 2013.
- BRASIL. Presidência da República. Plano Amazônia Sustentável: diretrizes para o desenvolvimento sustentável da Amazônia Brasileira. Brasília, 2008. 112 p.
- BRADY, M. e IRWIN, E. Accounting for spatial effects in economic models of land use: Recent developments and challenges ahead. *Environmental & Resource Economics* 48: 487–509, 2011.
- BRANDAO Jr., A.; SOUZA Jr., C. M.; RIBEIRO, J. G. F.; SALES, M. H. R.. Desmatamento e estradas não-oficiais da Amazônia. In: *Proceeding of the XIII Simpósio Brasileiro de Sensoriamento Remoto*. Florianópolis: INPE. 2005.
- CARVALHO, T. S. *Uso do Solo e Desmatamento nas Regiões da Amazônia Legal Brasileira: condicionantes econômicos e impactos de políticas públicas*. (Tese de Doutorado). Belo Horizonte: Centro de Desenvolvimento e Planejamento Regional (Cedeplar) Universidade Federal de Minas Gerais, 2014
- CHAKIR, R. AND PARENT, O.: Determinants of land use changes: A spatial multinomial probit approach, *Pap. Reg. Sci.*, 88, 327–344, 2009.
- CHAKIR, R. AND LE GALLO, J. Predicting land use allocation in France: A spatial panel data analysis. *Ecological Economics* 92: 114–125, 2013.
- CLIFF, A., ORD, J. *Spatial Autocorrelation*. Pion, London, 1973.
- CLIFF, A., ORD, J. *Spatial Processes, Models and Applications*. Pion, London, 1981

FEARNSIDE, P. M. Soybean cultivation as a threat to the environmental in Brazil. *Environmental Conservation*, vol. 28, n.1, p. 23-28, 2001b.

GAZZONI, D.L. O impacto do uso da terra na sustentabilidade dos biocombustíveis. Documentos. *Embrapa Soja*. N. 347. 2014.

GEIST, H. J.; LAMBIN, E. F. Proximate Causes and Underlying Driving Forces of Tropical Deforestation, *BioScience*, vol. 52, n. 2, p. 143-150, 2002.

IGLIORI, D.C. Deforestation, Growth and Agglomeration Effects: Evidence from Agriculture in the Brazilian Amazon. University of Cambridge, Department of Land Economy, Texto para Discussão, 28, 2008.

IRWIN, E. e GEOGHEGAN, J. Theory, Data, Methods: developing spatially-explicit economic models of land use change. *Agriculture, Ecosystems and Environment* 85, 7-24, 2001.

IRWIN, E. G. New Directions for Urban Economic Models of Land Use Change: Incorporating Spatial Dynamics and Heterogeneity. *Journal of Regional Science* , 50, 65-91, 2010.

IRWIN, E. G. e DOUGLAS, H. Wrenn. "An Assessment of Empirical Methods for Modeling Land Use", In J.M. Duke and J.J. Wu Edition, *Oxford Handbook of Land Economics*, (2014), Oxford University Press.

JEAN-SAUVEUR, A. Y.; CHAKIR, Raja; LE GALLO, Julie. Individual vs. aggregate models of land use changes: Using spatial econometrics to improve predictive accuracy?. 2014.

KAPOOR, M., KELEJIAN, H., PRUCHA, I. Panel data models with spatially correlated error components. *Journal of Econometrics* 140, 97–130, 2007.

LAPOLA, D. M., et al. Indirect land-use changes can overcome carbon savings from biofuels in Brazil. *Proceedings of the national Academy of Sciences*, v. 107, n. 8, p. 33883393, 2010.

LUBOWSKI, R., PLANTINGA, A., STAVINS, R. What drives land-use change in the United States? A national analysis of landowner decisions. *Land Economics* 84 (4), 551–572, 2008.

PLANTINGA, A.J., AHN, S. Efficient policies for environmental protection: an econometric analysis of incentives for land conversion and retention. *Journal of Agricultural and Resource Economics* 27 (1), 128–145, 2002.

PLANTINGA, A. AND IRWIN, E. Overview of empirical methods. *Economics of Rural LandUse Change*. Bell, K.P., Boyle, K.J., and Rubin, J., eds., *Ashgate Publishing*, 2006.

PF AFF, A. S. P. What Drives Deforestation in the Brazilian Amazon? Evidence from satellite and Socioeconomic Data. *Journal of Environmental Economics and Management*, vol. 37, p. 26-43, 1999.

RUDEL, T. K. et al. Agricultural Intensification and changes in cultivated areas, 1970-2005. *PNAS*, vol. 106, n. 49, p. 20675-20680, 2009b.

TURNER, B. L., LAMBIN, E. F. AND REENBERG, A. The emergence of land change science for global environmental change and sustainability. *Proceedings of the National Academy of Sciences* 104: 20666–20671, 2007

VERBURG, P.H., SCHOT, P.P., DIJST, M.J., VELDKAMP, A. Land use change modelling: current practice and research priorities. *GeoJournal* 61, 309–324, 2004.

WALKER, R., MORAN, E., ANSELIN, L. Deforestation and cattle ranching in the Brazilian Amazon: external capital and household processes. *World Development*, vol. 28, n. 4, p. 683–699, 2000.

WU, J., SEGERSON, K. The impact of policies and land characteristics on potential groundwater pollution in Wisconsin. *American Journal of Agricultural Economics* 77: 1033–1047, 1995.

WU, J. e DUKE, J. M.. The Oxford Handbook of Land Economics. *Oxford University Press*, USA. 2014.

## ANEXO A

Quadro 1: Definição das diferentes classes de terras monitoradas pelo projeto TerraClass

Classes de terras	Descrição
1 Desflorestamento	Áreas recentemente desmatadas cobertas por solo, arbustos, ervas e árvores derrubadas sem uso definido de terras nesta fase, definidas como áreas que foram mapeadas pelo projeto PRODES como desmatadas;
2 Área urbana	Concentração populacional que forma pequenos locais habitados, aldeias e cidades que apresentam infra-estrutura diferenciada das áreas rurais com design de rua e maior densidade de moradias, como casas, edifícios e outros espaços públicos.
3 Áreas de mineração	Áreas de extração mineral com presença de solo nu e desmatamento na proximidade de massas de água
4 Agricultura anual	Áreas extensas com predomínio de culturas de ciclo anual, sobretudo de grãos, com emprego de padrões tecnológicos elevados, tais como uso de sementes certificadas, insumos, defensivos e mecanização entre outros
5 Mosaico de ocupações	áreas extensas com predomínio de culturas de ciclo anual, sobretudo de grãos, com emprego de padrões tecnológicos elevados, tais como uso de sementes certificadas, insumos, defensivos e mecanização entre outros
6 Pasto limpo	áreas de pastagem com predomínio de vegetação herbácea, e cobertura de espécies de gramíneas entre 90% e 100%;
7 Pasto sujo	áreas de pastagem em processo produtivo com predomínio da vegetação herbácea e cobertura de espécies gramíneas entre 50% e 80%, associado à presença de vegetação arbustiva esparsa com cobertura entre 20% a 50%;
8 Regeneração com pasto	áreas que, após o corte raso da vegetação natural e o desenvolvimento de alguma atividade agropastoril, encontram-se no início do processo de regeneração da vegetação nativa, apresentando dominância de espécies arbustivas e pioneiras arbóreas. Áreas caracterizadas pela alta diversidade de espécies vegetais;
9 Pasto com solo exposto	áreas que, após o corte raso da floresta e o desenvolvimento de alguma atividade agropastoril, apresentam uma cobertura de pelo menos 50% de solo exposto;
10 Vegetação secundária	áreas que, após a supressão total da vegetação florestal, encontram-se em processo avançado de regeneração da vegetação arbustiva e/ou arbórea ou que foram utilizadas para a prática de silvicultura ou agricultura permanente com uso de espécies nativas ou exóticas.
11 Outros	Áreas não abrangidas por outras categorias, como afloramentos rochosos ou montanhosos, rios e bancos de areia, entre outros.
12 Área não observada	As áreas não podem ser interpretadas devido a nuvens ou sombra de nuvens no momento do viaduto satélites ou áreas recentemente queimadas

Fonte: Almeida et al. (2016)