

**Existe relacionamento espacial entre luzes noturnas e indicadores agropecuários?  
Uma abordagem exploratória multiescalar na Amazônia Legal**

Filipe Dias  
Doutorando em Geografia Física (USP)

**RESUMO**

As interações espaciais entre o rural e o urbano, o campo e a cidade modificaram-se com o processo de modernização do território brasileiro. Novos conteúdos e funções espaciais foram inseridos nas relações entre o campo e a cidade. Buscando explorar o relacionamento espacial entre variáveis mediadoras representativas do processo de urbanização e desmatamento dentro do escopo do processo de modernização do território, o presente trabalho adotou modelos espaciais de Regressão Geograficamente Ponderada (RGP) e Multiescalar (RGPM) para analisar padrões espaciais nos municípios da Amazônia Legal. Os resultados indicam que existe relacionamento espacial entre luzes noturnas e indicadores agropecuários em sub-regiões específicas da Amazônia Legal, e que tais relações estão vinculadas a uma commodity específica, como a soja no Norte de Mato Grosso e a pecuária no Sudeste do Pará.

## 1 INTRODUÇÃO

As interações espaciais entre o rural e o urbano, o campo e a cidade metamorfoseiam-se ao longo do tempo. As transformações decorrentes da modernização do território brasileiro remodelaram as lógicas espaciais da estrutura produtiva, assim como os conteúdos e as funções do campo e da cidade em determinadas regiões do país (MATOS; PESSOÃ, 2011; TRINDADE JÚNIOR, 2015). No entanto, este processo é caracterizado mais pela incorporação de novas áreas de formação florestal ao processo produtivo do que o aumento da produtividade advindos de avanços tecnológicos (SAUER; PIETRAFESA, 2013).

Na Amazônia brasileira, o desmatamento e a urbanização são um dos principais processos representativos da interação espacial entre o rural e o urbano. Suas relações são focos de uma gama de investigações caracterizadas por diferentes sistemas conceituais e de análises, de variáveis e indicadores (CORTÊS; SILVA JÚNIOR, 2021).

Feitosa e Monteiro (2012) argumentam que, para fenômenos e processos complexos, como a urbanização e o desmatamento, são necessárias estratégias de mediação para buscar compreender determinadas dimensões que os compõem. Neste sentido, os dados de sensoriamento remoto de luzes noturnas destacam-se como proxies de diversos fatores ambientais e socioeconômicos como a população urbana (AMARAL et al., 2006), a dinâmica urbana (ZHANG, 2011), as estimativas de CO<sub>2</sub> (LETU, 2014), e o PIB (MELLANDER, 2015), refletindo, assim, aspectos indicativos do processo de urbanização.

Zheng et al., (2020) expõem que as relações entre a dinâmica do uso e cobertura da terra e as luzes noturnas possuem abordagens incipientes, e enfatizam para a importância e a necessidade de metodologias de análise espaciais adequadas. A Regressão Geograficamente Ponderada (RGP) é uma técnica exploratória de padrões espaciais entre variáveis socioeconômicas e ambientais amplamente utilizada (SU et al., 2012; CHEN et al., 2020). No entanto, o caráter multidimensional e multiescalar dos componentes do processo de desmatamento na Amazônia Legal é reduzido, pois a técnica os limita à mesma escala de realização. Buscando superar tal limitação, Fotheringham et al. (2017) expandiram a RGP e desenvolveram a Regressão Geograficamente Ponderada Multiescalar (RGPM), na qual cada componente de um determinado fenômeno ou processo atuará em uma escala espacial.

Dessa forma, o presente trabalho busca realizar uma análise exploratória entre os dados de luzes noturnas e indicadores agropecuários relacionados ao processo de

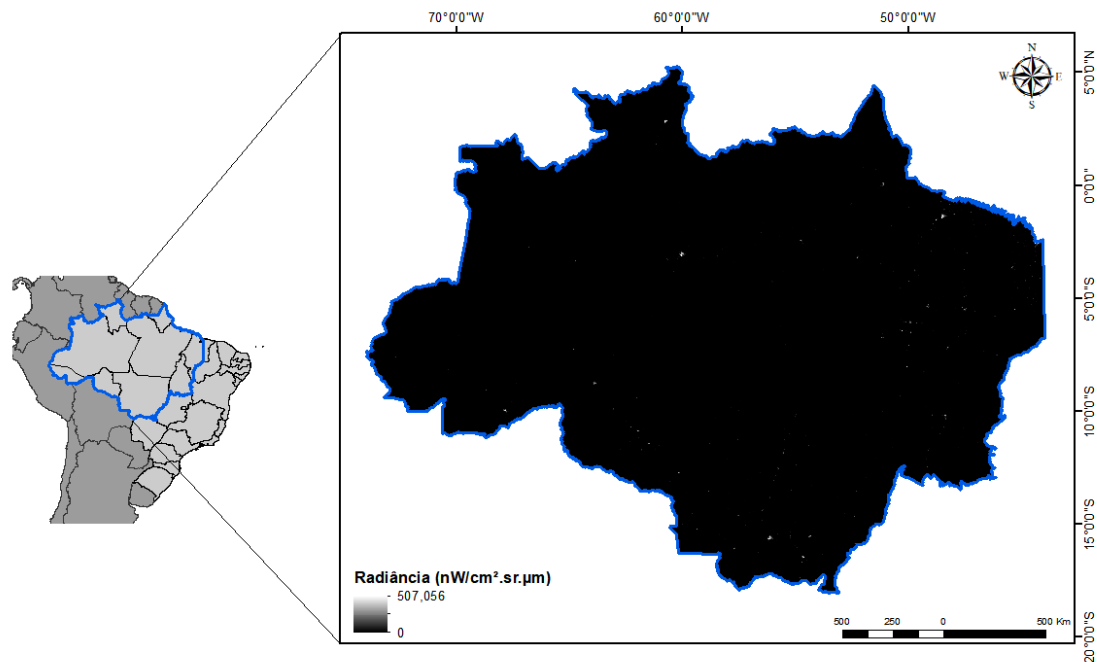
desmatamento na Amazônia Legal através da comparação dos modelos RGP e RGPM. O intuito do trabalho não é de se estabelecer relação causal entre os processos, mas de analisar possíveis relações e padrões espaciais entre as variáveis mediadoras frente às recentes transformações no espaço agrário amazônico.

## 2 MATERIAIS E MÉTODOS

### 2.1 Área de estudo

A Amazônia Legal (Figura 1) é o recorte utilizado como unidade de análise do trabalho. A área de estudo consiste de uma regionalização com fins de planejamento e implementação de políticas públicas que abrange municípios dos estados do Pará, Amazonas, Amapá, Acre, Roraima, Rondônia, Tocantins, Mato Grosso e Maranhão.

Figura 1 – Representação da situação geográfica da Amazônia Legal.



Fonte: Elaborado pelo autor.

Os dados do Instituto Brasileiro de Geografia e Estatística (IBGE) mostram que a Amazônia Legal corresponde a 58,9% do território brasileiro. Por outro lado, a região possui a menor densidade demográfica do país, cuja população compreende cerca de 13,2% do total. Das atividades econômicas desenvolvidas na área, o comércio e serviços detém o maior percentual do PIB com 36,8%, seguido da indústria com 20,3% e das atividades agropecuárias com 10,6%, que, no geral, representam uma participação de 8,7% do PIB brasileiro.

A região apresenta transformações intensas da cobertura e do uso da terra, sendo a agropecuária, a mineração e os projetos de infraestrutura os principais vetores responsáveis (AGUIAR et al., 2007; SONTER et al., 2017; SANTOS et al., 2021). A configuração da paisagem até o ano de 2018, de acordo com o projeto MapBiomas, era composta de 60,3% de áreas de formação florestal e 30,4% de áreas relacionadas às atividades agropecuárias. Seguindo ainda nessa linha, e tomando um contexto histórico recente, os dados do DETER do Instituto Nacional de Pesquisas Espaciais (INPE) revelam uma crescente significativa nas taxas de desmatamento a partir do ano de 2012.

## 2.2 Sistematização do banco de dados

As variáveis utilizadas para analisar a relação espacial entre luzes noturnas e indicadores agropecuários estão descritas no Quadro 1. A seleção dos indicadores agropecuários está baseada na literatura sobre os alguns dos fatores que impulsionam a dinâmica do uso e cobertura da terra na Amazônia Legal como Aguiar et al., (2007), Jusys (2016) e Kuschning et al., (2021). A seleção dos indicadores e o recorte temporal de análise limitou-se na disponibilidade e compatibilidade dos dados, além do intuito de analisar a relação em um contexto mais recente, refletindo-se no período de 2012 a 2018.

Quadro 1 – Variáveis representativas dos dados de luzes noturnas e indicadores agropecuários.

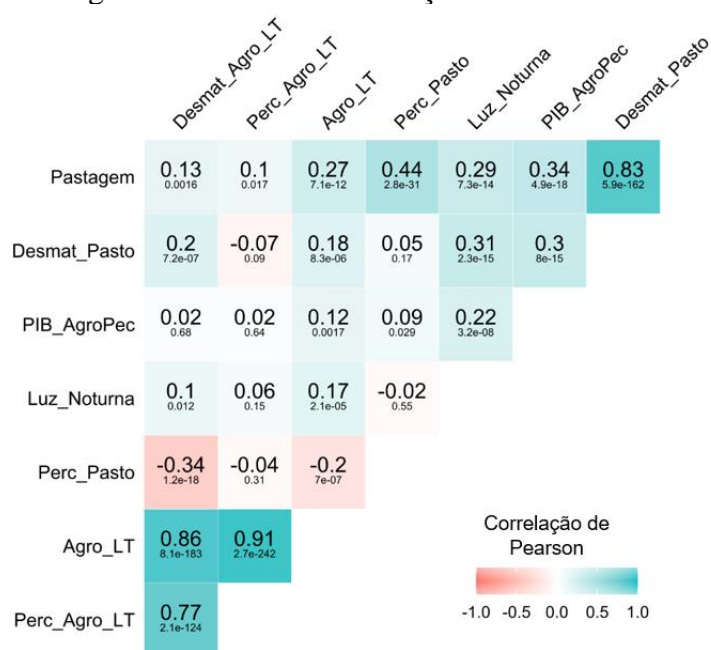
Variáveis	Descrição	Unidade	Ano	Fonte
<b>Luz_Noturna</b>	Soma total dos valores medianos de radiância no município.	nW/cm <sup>2</sup> .sr.µm	2018	VIIRS/EOG
<b>Pastagem</b>	Quantidade areal de pasto no município.	Km <sup>2</sup>	2018	Mapbiomas
<b>Desmat_Pasto</b>	Taxa de conversão de áreas florestais para pasto no município.	Km <sup>2</sup>	2012-2018	Mapbiomas
<b>Perc_Pasto</b>	Percentual de pasto em relação à área do município.	Km <sup>2</sup>	2018	Mapbiomas IBGE
<b>PIB_AgroPec</b>	Valor bruto das atividades agropecuárias adicionado ao PIB.	Reais	2018	IBGE

<b>Agro_LT</b>	Área de agricultura de lavoura temporária no município.	Km <sup>2</sup>	2018	MapBiomias
<b>Desmat_Agro_LT</b>	Taxa de conversão de áreas florestais para lavoura temporária no município.	Km <sup>2</sup>	2012-2018	MapBiomias
<b>Perc_Agro_LT</b>	Percentual de agricultura de lavoura temporária em relação à área do município.	Km <sup>2</sup>	2018	Mapbiomas IBGE

## 2.2 Análise exploratória dos dados

Após a definição das variáveis representativas das luzes noturnas e indicadores agropecuários, realizou-se uma análise exploratória a fim de verificar a correlação entre os dados, cujo objetivo é selecionar variáveis com algum grau de correlação estatisticamente significativa com o dado de luz noturna, e evitar a multicolinearidade entre as variáveis dos indicadores agropecuários a partir da não inclusão no modelo daquelas com correlação maior ou igual a 0,8. A Figura 2 apresenta a correlação e a significância estatística entre as variáveis.

Figura 2 – Matriz de correlação entre as variáveis.

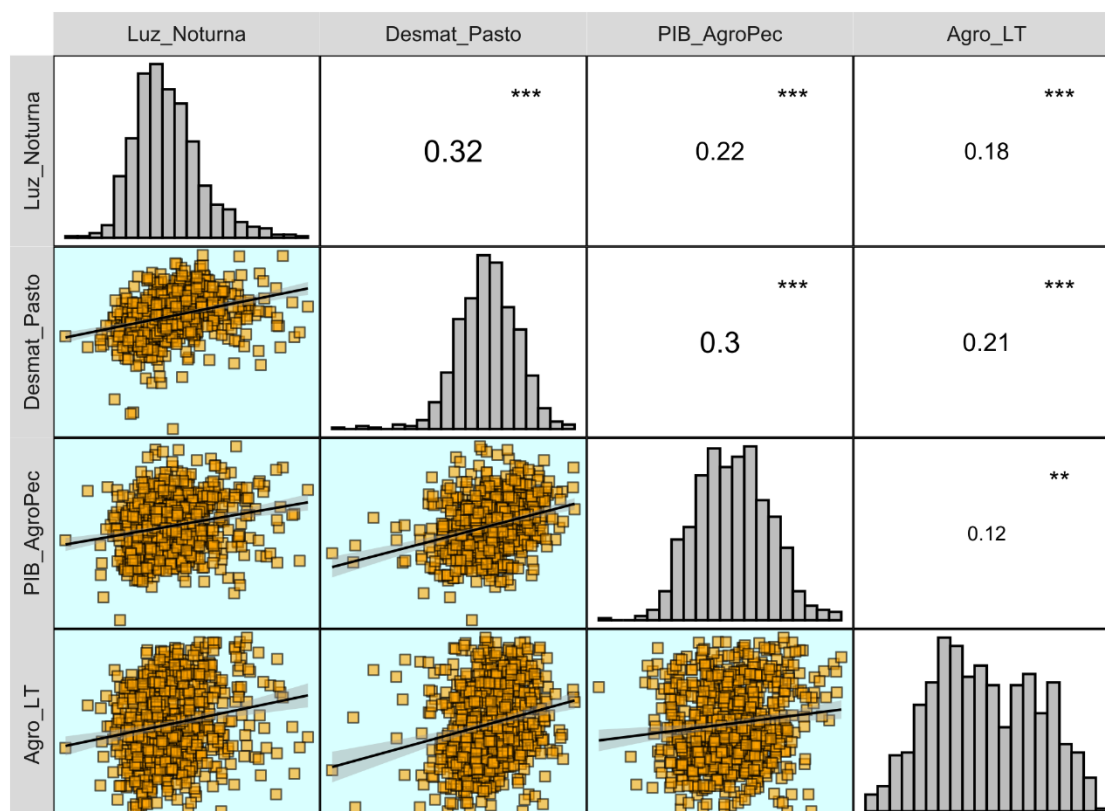


Fonte: Elaborado pelo autor.

Com base nas informações da matriz de correlação, as variáveis “Desmat\_Pasto”, “PIB\_AgroPec” e “Agro\_LT” foram selecionadas para representar os indicadores agropecuários como variáveis independentes nos modelos de regressão, sendo a variável “Luz\_Noturna” a dependente.

A distribuição dos dados também foi analisada para verificar se seguiam uma distribuição normal. Todas as variáveis não apresentaram uma distribuição normal. Com isso, aplicou-se um logaritmo de base 10 para normalizá-las ou minimizar os efeitos que variáveis não normais podem resultar, conforme abordado por Yu et al., (2014). A Figura 3 representa a dispersão, correlação e a distribuição das variáveis após a transformação logarítmica.

Figura 3 – Gráfico de dispersão, correlação e distribuição das variáveis de luz noturna e indicadores agropecuários dos municípios da Amazônia Legal.



Fonte: Elaborado pelo autor.

O gráfico demonstra que a relação das variáveis de luz noturna e indicadores agropecuários apresentam linearidade e correlação fraca, e que, mesmo após a transformação logarítmica, as variáveis não apresentam normalidade, no entanto, possuem uma distribuição aproximada ou semelhante.

### 2.3 Regressão Geograficamente Ponderada e Multiescalar

Para analisar a relação espacial entre luzes noturnas e indicadores agropecuários dos municípios da Amazônia Legal, utilizou-se a RGP e sua variação RGPM. O ponto de partida desses métodos é a Regressão Linear (RL), que é dada de acordo com a Equação (1) abaixo.

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \beta_n X_n + e_i \quad (1)$$

Onde  $Y$  é a variável dependente observada,  $\beta_0$  é o intercepto da regressão,  $\beta_n$  é o n-ésimo coeficiente estimado, já  $X_n$  é a n-ésima variável independente, enquanto  $e_i$  é o erro estimado da regressão.

O modelo de RL do presente trabalho é expresso na Equação (2). A partir da modelagem dos parâmetros estimados, foi realizada a verificação da normalidade e heterocedasticidade do modelo através do teste de Jarque-Bera e Breusch-Pagan, respectivamente, assim como a autocorrelação espacial dos resíduos por meio do Índice de Moran.

$$\log_{10}(Luz_{Noturna})_i \sim \beta_0 + \beta_1 \log_{10}(Desmat_{Pasto})_i + \beta_2 \log_{10}(PIB_{AgroPec})_i + \beta_3 \log_{10}(Agro_{LT})_i + e_i \quad (2)$$

Os resultados dos testes do modelo RL demonstram a heterogeneidade espacial, haja vista que os testes de normalidade (2.2e-16) e heterocedasticidade (0.032) não rejeitaram a hipótese nula, assim como uma certa dependência espacial da relação entre os dados de luzes noturnas e indicadores agropecuários, cujo Índice de Moran foi igual a 0.23 com dois vizinhos espaciais.

Considerando o relacionamento espacial entre a variável dependente e as variáveis independentes, aplicou-se a RGP e a RGPM. Enquanto a RL é um método global, que estima os parâmetros do modelo de maneira constante no espaço, a RGP (Equação 3) permite estimar os parâmetros localmente.

$$Y_i = \beta_0(u_i v_i) + \beta_1 X_1(u_i v_i) + \beta_2 X_2(u_i v_i) + \beta_n X_n(u_i v_i) + e_i \quad (3)$$

Onde  $u_i v_i$  é a localização das observações da n-ésima variável. No presente trabalho, adotou-se as coordenadas geográficas das sedes municipais como o centróide da regressão.

A estimação dos parâmetros locais da RGP é feita por meio da seleção da Largura de Banda (LB). A LB representa a escala de operação das variáveis, ou seja, a distância em que os processos atuam de maneira similar (HONG; YOO, 2020). A definição da LB é realizada através da otimização do critério de informação de Akaike corrigido (AICc), dado na Equação (4) abaixo. O valor que obtiver o melhor ajuste de AICc, ou seja, o menor valor de AICc, é selecionado como a LB da RGP.

$$AICc = 2n \ln(\hat{\sigma}) + n \ln(2\pi) + n \frac{n+tr(S)}{n-2-tr(S)} \quad (4)$$

Onde  $\hat{\sigma}$  é o desvio padrão estimado do termo de erro,  $tr(S)$  corresponde a uma matriz de pesos espaciais. A LB de melhor ajuste selecionada entre as variáveis do trabalho em questão foi igual a 142.

Outros parâmetros importantes a serem destacados na modelagem da RGP do trabalho foi a utilização de um Kernel espacial biquadrado adaptativo, *golden section* como rotina de seleção da LB e um modelo do tipo Gaussiano.

A limitação da RGP é adotar a mesma escala de atuação para os diferentes processos. Para superar essa limitação, Fotheringham et al. (2017) desenvolveram a RGPM, em que cada fenômeno ou processo possui a sua própria escala de realização, em outras palavras, cada variável tem a sua LB. A RGPM é dada de acordo com a Equação (5) abaixo.

$$Y_i = \beta_{0_{lb}}(u_i v_i) + \beta_{1_{lb}} X_1(u_i v_i) + \beta_{2_{lb}} X_2(u_i v_i) + \beta_{n_{lb}} X_n(u_i v_i) + e_i \quad (5)$$

Onde  $lb$  é a largura de banda de cada parâmetro beta local estimado para a variável em questão.

A calibração do modelo RGPM é diferente do RGP. Para alcançar uma LB para cada variável no modelo de regressão, Fotheringham et al. (2017) desenvolveram a RGPM como um modelo aditivo generalizado. Para detalhes do processo de calibração da RGPM, consultar os autores supracitados. Os resultados da modelagem estão na Tabela 1 abaixo.

Tabela 1 – Parâmetros dos modelos RGP e RGPM.

Diagnóstico da Informação	RGP	RGPM		
		Desmat_Pasto	PIB_AgroPec	Agro_LT
LB	142	320	59	668
NPE	46.768	1.825	11.855	1.437



T crítico (95%)	2.867	2.211	2.871	2.115
-----------------	-------	-------	-------	-------

Fonte: Elaborado pelo autor.

Após a modelagem da RGP e RGPM, verificou-se a significância estatística dos coeficientes betas por meio dos testes de hipóteses. O valor do T crítico define o primeiro nível de significância e é obtido através do Número de Parâmetros Efetivos (NPE) de cada modelo e/ou de cada variável, conforme apresentado na tabela 1. A significância estatística do T crítico pelo P valor configura os padrões espaciais após múltiplos testes de hipóteses. Os detalhes matemáticos para obtenção do T crítico podem ser consultadas em Oshan et al. (2020).

Os modelos RGP e RGPM foram processados no software MGWR 2.2, disponibilizado pela Arizona State University. E os resultados dos modelos foram espacializados em mapas temáticos no software QGIS 3.16.

### 3 RESULTADOS

Os resultados da RL estão sumarizados na Tabela 2. Todos os indicadores agropecuários apresentaram relação positiva com a luz noturna. A variável “Desmat\_Pasto” teve o maior valor de beta estimado, enquanto “Agro\_LT” teve o menor. As variáveis do modelo também foram estatisticamente significantes, exceto o intercepto, devido a padronização das variáveis, a qual possibilita a comparação entre os valores de beta (OSHAN et al., 2020).

Tabela 2 – Resultados da Regressão Linear.

N = 669				
Variável	$\beta$ estimado	Desvio Padrão	T-valor	P-valor
Intercepto	-0.000	0.036	-0.000	1.000
Desmat_Pasto	0.255	0.039	6.614	0.000 ***
PIB_AgroPec	0.134	0.038	3.527	0.000 ***
Agro_LT	0.113	0.037	3.046	0.002 **

Fonte: Elaborado pelo autor.

A Tabela 3 abaixo apresenta a estatística descritiva dos coeficientes betas estimado para a RGP e a RGPM. Os modelos possuem valores similares entre as variáveis. A diferença resulta dos maiores valores médios no modelo RGPM para todas as variáveis. Em comparação com a RL, todas as variáveis também são positivas e o beta médio estimado, em ambos os modelos, são maiores. Além disso, a variável “PIB\_AgroPec” possui a menor magnitude entre as variáveis nos modelos.

Tabela 3 – Estatística descritiva dos modelos RGP e RGPM.

Variável	RGP			RGPM		
	$\beta$ médio	$\beta$ mínimo	$\beta$ máximo	$\beta$ médio	$\beta$ mínimo	$\beta$ máximo
Intercepto	-0.050	-1.014	0.768	-0.056	-0.751	0.695
Desmat_Pasto	0.235	-0.413	0.701	0.268	0.060	0.395
PIB_AgroPec	0.079	-0.270	0.709	0.096	-0.439	1.043
Agro_LT	0.245	-0.003	0.763	0.260	0.217	0.273

Fonte: Elaborado pelo autor.

Os modelos RGP e RGPM também apresentaram maior ajuste aos dados de luz noturna e indicadores agropecuários dos municípios da Amazônia Legal, e poder de explicação em relação ao modelo RL, conforme demonstra a Tabela 4.

Tabela 4 – Comparação dos ajustes dos modelos RL, RGP, RGPM.

Parâmetros	RL	RGP	RGPM
R <sup>2</sup> ajustado	0.128	0.267	0.294
AICc	1814.124	1745.113	1727.271
RSS	580.866	455.964	435.357
Log-Likelihood	-902.017	-821,032	-805.563

Fonte: Elaborado pelo autor.

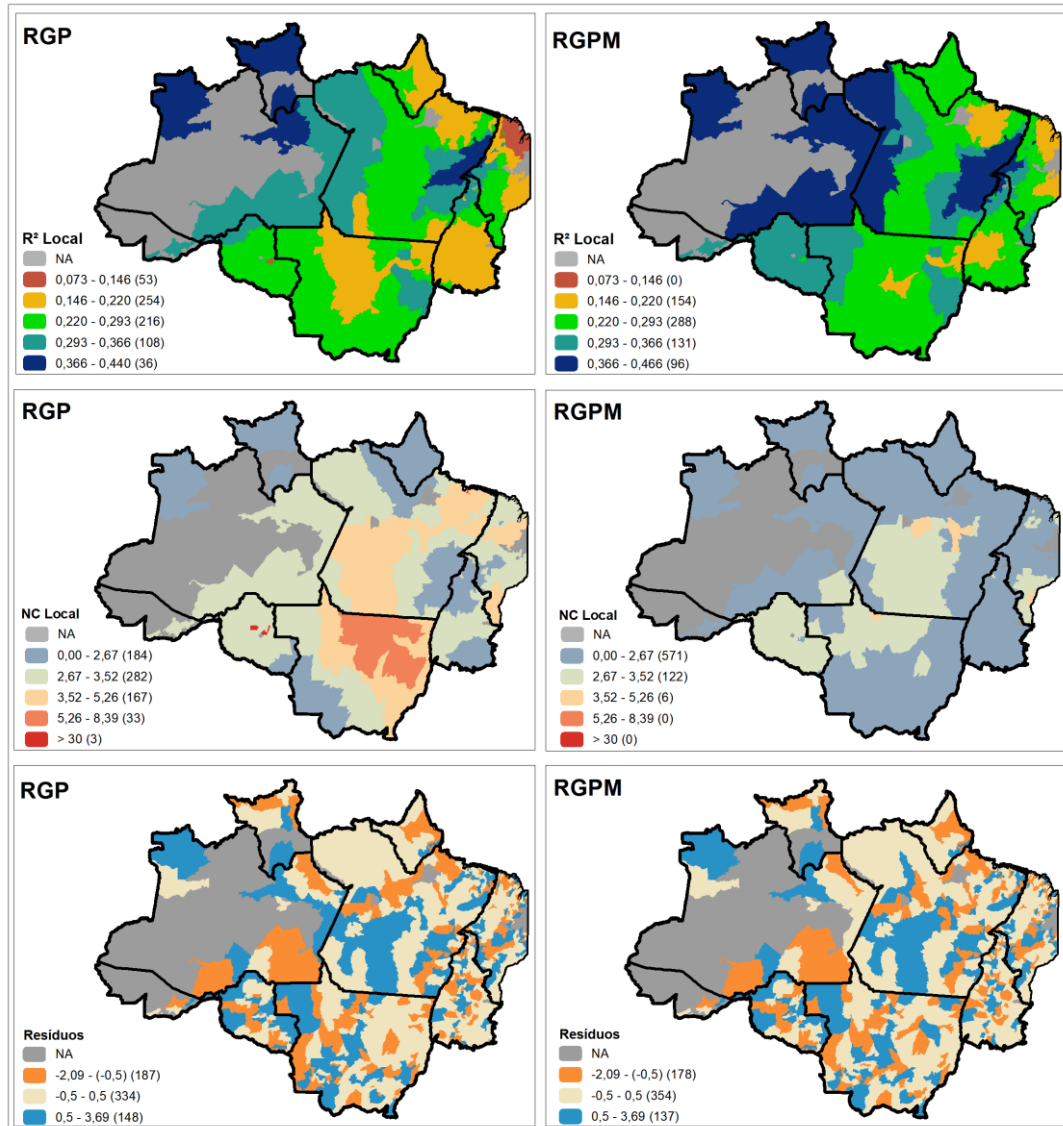
O coeficiente de determinação R<sup>2</sup> da RGPM foi o maior dentre os modelos, em que os indicadores agropecuários selecionados para o modelo explicam cerca de 29% da variação média da luz noturna nos municípios da Amazônia Legal, enquanto a RGP explica 26% e a RL cerca de 12%. Dos parâmetros de ajustes, aqueles que possuem menores valores indicam os melhores ajustes. Todos os parâmetros mostram que a RGPM possui o melhor ajuste dos dados analisados.

A Figura 4 representa os resultados do coeficiente de determinação R<sup>2</sup>, os Números Condicionais (NC) e os resíduos locais dos municípios da Amazônia Legal para os modelos RGP e RGPM.

Dos municípios da Amazônia Legal analisados, 68,90% apresentam um R<sup>2</sup> Local igual ou maior a 20% no modelo RGP, enquanto no modelo RGPM esse valor é igual a 87,74%. Os resultados do R<sup>2</sup> para os modelos RGP e RGPM demonstram padrões espaciais semelhantes, sendo o efeito de escala dos valores o principal responsável pela diferenciação entre os padrões dos modelos. Tanto no RGP quanto no RGPM, os padrões espaciais de maiores valores de R<sup>2</sup> estão nos municípios do Pará, Amazonas e Roraima. O município de Ulianópolis, no sudeste paraense, foi o único a possuir o R<sup>2</sup> maior do que 40% no modelo RGP, diferente do RGPM em que um conjunto de municípios ultrapassam esse percentual. O aumento do R<sup>2</sup> do RGPM em relação ao RGP expressa dois pontos importantes nos padrões espaciais, a quais estão relacionados ao efeito de

escala mencionado anteriormente: 1) Acréscimo no número de municípios do Pará e Amazonas na maior classe de  $R^2$ , e 2) a inclusão de municípios no Norte de Mato Grosso, no Baixo Amazonas e Sudeste paraense, a quase totalidade dos municípios de Rondônia e os municípios no Sul do Maranhão na segunda maior classe de  $R^2$ .

Figura 4 – Representação do  $R^2$  Local, NC Local e os Resíduos Locais.

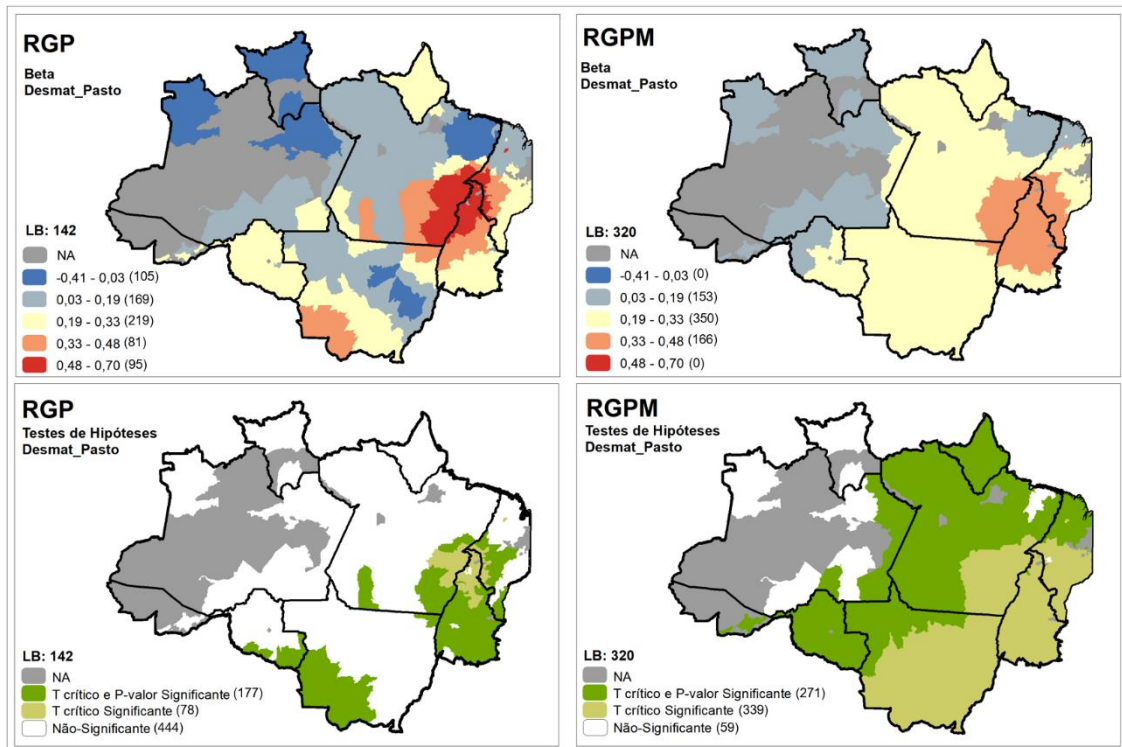


Fonte: Elaborador pelo autor.

A multicolinearidade foi majoritariamente baixa em ambos os modelos, sobretudo no modelo RGPM. Os municípios de Ouro Preto do Oeste e Cacaulândia, em Rondônia, e o município de Vigia, no Pará, foram as exceções e apresentaram NC Local maior do que 30 no modelo RGP. Os resíduos em ambos os modelos são semelhantes. Os valores predominam em torno de zero, no entanto, o número de municípios com resíduos menor do que -0,5 e maior do que 0,5 dá indicativos da heterogeneidade espacial da relação entre luz noturna e indicadores agropecuários na Amazônia Legal.

A Figura 5 representa os coeficientes betas da variável independente “Desmat\_Pasto” para os modelos RGP e RGPM, assim como os municípios da Amazônia Legal que apresentaram significância estatística nos testes de hipóteses.

Figura 5 – Coeficiente beta e significância estatística da variável “Desmat\_Pasto”.



Fonte: elaborado pelo autor.

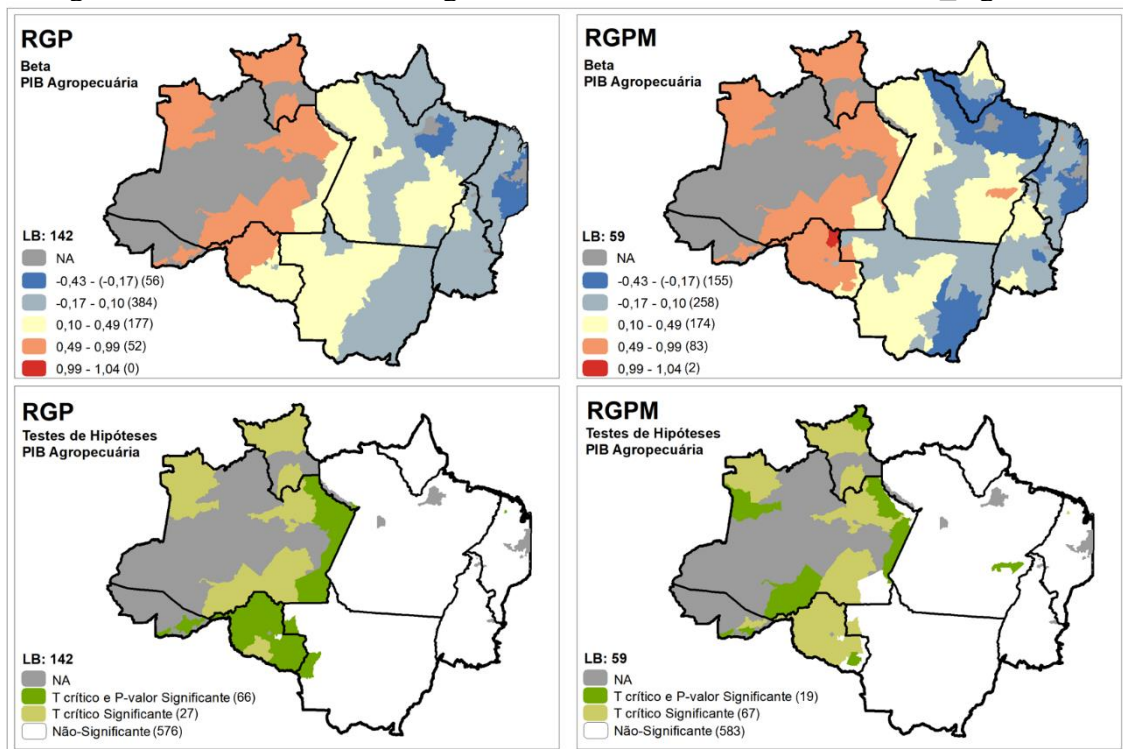
Os padrões espaciais dos modelos demonstram que a relação entre a conversão de áreas florestais para pastagem e luzes noturnas é maior na região da Amazônia Oriental formada pelo sudeste paraense, centro-norte do Tocantins e o oeste e sul maranhense. Nesta região, a conversão de 1 km<sup>2</sup> de formação florestal para pasto resulta em um aumento médio entre 0,33 a 0,70 nW/cm<sup>2</sup>.sr.µm na luz noturna dos municípios. Marabá, no Pará, Araguaína, no Tocantins, e Imperatriz, no Maranhão, são alguns dos municípios contidos nesta região. Estes possuem uma importância regional relacionada aos serviços e comércios vinculados às atividades agropecuárias, além do setor primário sólido em si, com um quantitativo de rebanho de gado expressivo (IBGE, 2020).

A diferença de LB entre os modelos expressa dois pontos importantes nos padrões espaciais. O primeiro está relacionado a padrões espaciais mais detalhados no modelo RGP. Municípios do sudoeste e centro-sul de Mato Grosso, como Cáceres, apresentam maior relação das variáveis no RGP do que no RGPM. Já o oposto é encontrado em um eixo sudeste-noroeste no Mato Grosso, em grande parte dos municípios do Pará e alguns municípios do norte do Maranhão.

O segundo diz respeito à significância estatística dos padrões espaciais. O número de municípios com significância estatística da relação entre luz noturna e a conversão de formação florestal para pasto é menor no modelo RGP. No entanto, os padrões com os maiores valores de beta, em grande parte, apresentaram significância tanto no teste T crítico quanto no teste P-valor, sendo o contrário apresentado pelo modelo RGPM. De qualquer modo, os padrões espaciais resultantes dos testes de hipóteses em ambos os modelos mostram que o relacionamento espacial entre luz noturna e o desmatamento para pasto é significativo em um quantitativo expressivo de municípios da Amazônia Legal, entretanto, o impacto dessa relação é maior no sudeste paraense, no oeste do Maranhão, em quase todos os municípios do Tocantins e no Sudoeste do Mato Grosso.

A Figura 6 apresenta os coeficientes betas e a significância estatística da relação entre luz noturna e o PIB agropecuário nos municípios da Amazônia Legal. Os resultados demonstram que tal relação foi maior, sobretudo, em municípios do Acre, Amazonas, Rondônia e Roraima. O incremento de R\$ 1.000,00 bruto no PIB agropecuário aumenta em média entre 0,49 a 0,99 nW/cm<sup>2</sup>.sr.µm na luz noturna de tais municípios.

Figura 6 – Coeficiente beta e significância estatística da variável “PIB\_AgroPec”.



Fonte: Elaborado pelo autor.

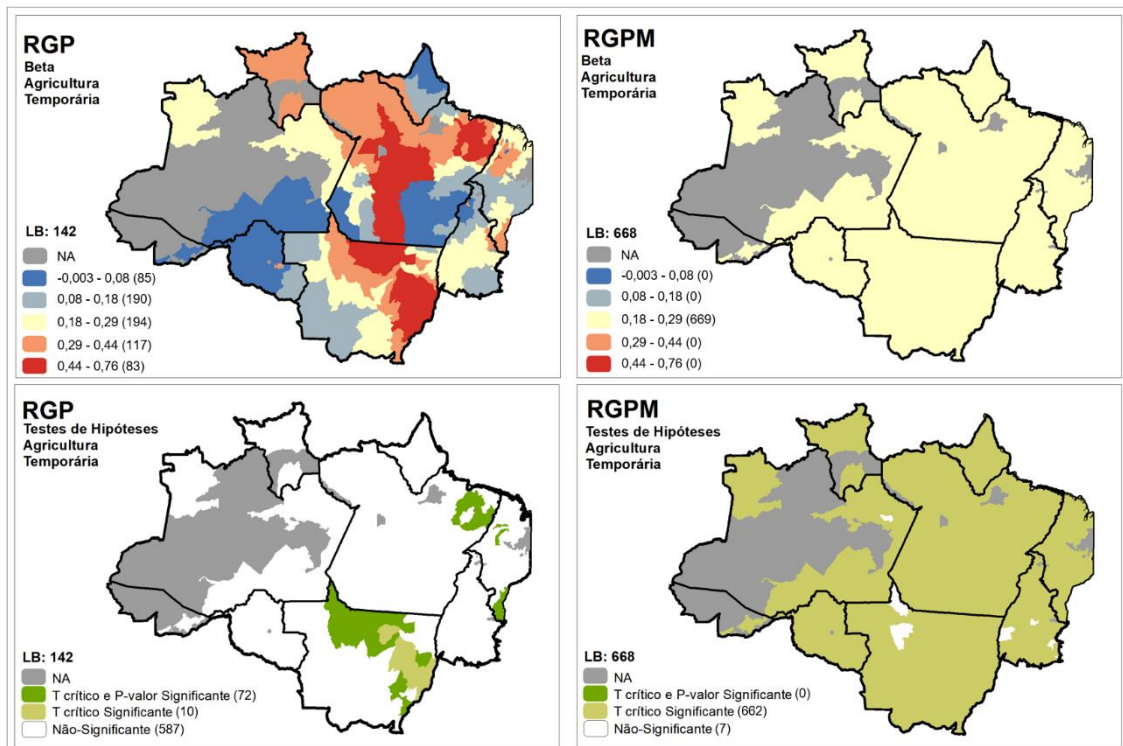
A diferença de LB entre os modelos não resultou em padrões espaciais expressivamente diferenciados. Estes ficam por conta do efeito de escala positivo em alguns municípios do Amazonas, do Pará e de Rondônia. Ariquemes, Cacoal e Ji-Paraná,

em Rondônia, Lábrea e Parintins, no Amazonas, Parauapebas, Curionópolis e Eldorado do Carajás, no Pará, Assis Brasil, no Acre, e Pacaraima, em Roraima, são exemplos de municípios com relacionamentos espaciais significativos entre luz noturna e PIB agropecuário.

Os resultados dos testes de hipóteses demonstram que a variável “PIB\_Agropec”, diferentemente da variável discutida anteriormente, foi mais significativa na Amazônia Ocidental. O modelo RGP apresentou maior quantidade de municípios significantes considerando o T crítico e o P-valor, sobretudo no estado de Rondônia. A diferença dos municípios significativos entre os modelos, os quais majoritariamente se complementam, sugere que tal variável, por sintetizar diferentes produtos agropecuários, pode expressar significância em função da predominância de uma determinada atividade agropecuária no município e a sua escala de realização.

A Figura 7 representa os coeficientes betas e a significância da relação entre luzes noturnas e a variável independente “Agro\_LT” nos municípios da Amazônia Legal. A LB selecionada pelo modelo RGPM entende que a agricultura temporária atua de maneira global na área de estudo, o que não corresponde com a realidade da região. O reflexo desta LB se dá nos testes de hipóteses, em que nenhum município obteve significância tanto no T crítico quanto no P-valor.

Figura 7 – Coeficiente beta e significância estatística da variável “Agro\_LT”.



Fonte: Elaborado pelo autor.

O modelo RGP apresenta padrões espaciais significativos. Destacam-se os maiores coeficientes betas em regiões específicas dos estados do Pará, Mato Grosso e Maranhão, são elas: 1) Nordeste paraense; 2) Norte, Nordeste e Sudeste de Mato Grosso; e 3 Oeste e Sul do Maranhão.

No Nordeste paraense, Paragominas é um dos principais polos produtores de soja no Pará (BRITO et al., 2021). A área ocupada pela lavoura cresceu substancialmente entre 2012 e 2018, fazendo-o estar entre os 30 principais municípios produtores de soja da Amazônia Legal. Por outro lado, os demais municípios significativos no padrão espacial dessa região não apresentam a expansão de uma lavoura temporária semelhante a Paragominas. Pelo contrário, esses municípios são reconhecidos por formarem um dos principais polos produtores do monocultivo de dendê, uma lavoura permanente. O dendê é uma commodity de grande importância nacional e internacional e foi responsável por intensas dinâmicas do uso e cobertura da terra na região (DIAS; LIMA, 2021). Isso nos indica possíveis erros no mapeamento do dado utilizado, o que recomenda cautela na interpretação da relação entre as variáveis nesses municípios.

Em Mato Grosso, municípios como Campinápolis e Pontal do Araguaia, no leste do estado, e Alta Floresta e Sinop, no Norte, apresentaram significância estatística entre luzes noturnas e agricultura temporária. A expansão das lavouras de soja e milho, entre 2012 e 2018, é um denominador comum entre tais municípios. Nos municípios que apresentaram significância somente no teste T crítico também ocorreu o crescimento da soja e do milho, indicando que o relacionamento entre as variáveis pode ser significativo em diferentes recortes temporais.

Os municípios significativos no Maranhão também estão relacionados à expansão da lavoura de milho e soja. O padrão espacial formado pelos municípios de Tasso Fragoso e Alto Parnaíba, no sul do estado, está relacionado à região composta pelo conjunto de municípios dos estados do Maranhão, Tocantins, Piauí e Bahia, a qual denomina-se como MATOPIBA, onde a fronteira agropecuária avança crescentemente ao longo dos anos. Os municípios significativos do oeste do estado também estão diretamente relacionados à soja, como Buriticupu, onde a área ocupada pela lavoura entre 2012 e 2018 teve um dos maiores percentuais de crescimento dentre os municípios da Amazônia Legal.

#### **4 DISCUSSÃO**

Os dados analisados ressaltam algumas das diversas relações entre o rural e o urbano na Amazônia Legal. Os resultados obtidos expressam, sobretudo, as dimensões

econômicas e sociais do relacionamento entre tais categorias, uma vez que as luzes noturnas são altamente correlacionadas com o PIB (MELLANDER, 2015) e com a população e área urbana (AMARAL et al., 2006; ZHANG, 2011).

A relação entre o urbano e a fronteira agropecuária na Amazônia está bem documentada na literatura (BECKER, 1990; 2001; 2004; 2005; 2013). Richards e VanWey (2015) esquematizaram uma periodização do crescimento urbano na Amazônia em três momentos: 1) o ciclo econômico da borracha no fim do século XIX; 2) os projetos de ocupação nas décadas de 1970 e 1980; e 3) o processo de globalização nas últimas décadas. É com base neste terceiro momento que se busca discutir os resultados anteriormente explanados. No entanto, sabe-se que as formas e processos atuais também estão intrinsecamente relacionadas às ações pretéritas realizadas nos demais períodos históricos.

Silva (2015) destaca que o urbano e a constituição de uma rede urbana foram primordiais para a incorporação da Amazônia aos circuitos espaciais da economia capitalista, e que a articulação entre o grande capital, o Estado, as populações das cidades e das populações tradicionais configuraram uma fronteira agrícola multidimensional e multiescalar.

O caráter multidimensional e multiescalar da fronteira agropecuária na Amazônia é caracterizado, sobretudo, mas não restrito a isto, pelas demandas econômicas externas à região, o que acaba por definir um papel estratégico de mediação do local ao global às pequenas cidades e aos centros urbanos regionais, que, por sua vez, impulsiona nestas um incremento populacional significativo e novos elementos urbanos, processo denominado de urbanização difusa (TRINDADE JÚNIOR, 2015).

Tais demandas caracterizam a ação do capital globalizado. Esta ocasiona uma série de transformações territoriais no espaço rural de sub-regiões da Amazônia, onde se intensifica a produção de grãos e a pecuária, que logo são exportados para os grandes centros da economia nacional e global. Esse processo configura, ao mesmo tempo, as múltiplas escalas de realizações das atividades agropecuárias e a fragmentação do espaço regional Amazônico (SILVA, 2015). A espacialização deste processo se materializa, segundo Silva (2015), sobretudo, nos estados do Mato Grosso e, em menor magnitude, Rondônia e no Sudeste paraense, o que de certa forma corrobora com os resultados obtidos no presente trabalho.

Os municípios de expansão da fronteira da soja mapeadas na Amazônia por Labruna e Pereira (2011) são justamente àqueles que apresentaram os maiores valores de



R<sup>2</sup> e significância estatística em algum teste de hipótese nas variáveis “Agro\_LT” e “PIB\_AgroPec” nos modelos espaciais locais. Algumas características destes espaços são a mecanização agrícola, a aceleração do processo de urbanização, além de um ordenamento do território de acordo com os interesses das empresas e agentes do agronegócio. Esta relação também é caracterizada por uma série de impactos socioambientais como a perda da biodiversidade, poluição por agrotóxicos e a expropriação do homem do campo (LABRUNA; PEREIRA, 2011).

Richards e VanWey (2015) argumentam que o crescimento urbano na Amazônia nas últimas décadas se dá de forma acelerada nas cidades relacionadas à produção de commodities, considerando-o, assim, um sintoma dos interesses internacionais nos recursos naturais da região. Os autores ressaltam que a dinâmica do agronegócio não apenas ocasiona transformações na paisagem das regiões, mas modela e remodela cidades para apoiar, absorver, circular e consumir o capital gerado nas áreas rurais (RICHARDS; VANWEY, 2015).

Na mesma linha de raciocínio, Arruda (2012) expõe que, embora o espaço rural seja a unidade produtiva da agropecuária moderna, é o conjunto de sistemas informacionais e financeiros presentes nas cidades que possibilita a reprodução ampliada do capital. A presença de instituições bancárias e serviços especializados à atividade agropecuária dinamiza, segundo a autora, a economia urbana das cidades e impulsiona uma maior interação espacial entre o processo produtivo no campo e os setores secundário e terciário das cidades.

Silva (2017) descreve bem esta relação ao analisar a centralidade urbano-regional de Araguaína/TO no processo de produção da pecuária capitalista. O autor destaca a concentração de agroindústrias e a influência da atividade na produção e organização do espaço urbano. Isto se dá pela concentração de lojas e serviços especializadas em produtos e insumos agropecuários nas principais ruas e avenidas de acesso da cidade. Araguaína desempenha, assim, de acordo com o autor, um papel de controle da produção da pecuária no espaço regional e papel de mediação do abastecimento dos produtos no mercado interno e externo.

Um ponto importante abordado na análise de Richards e VanWey (2015), na qual é excluída os municípios do Maranhão e Tocantins, é a heterogeneidade das commodities que estão correlacionadas ao crescimento urbano no espaço regional amazônico. Os autores argumentam que a pecuária se expande por toda a Amazônia, mas é na região Sudeste do Pará que a atividade acelera o crescimento urbano. Estas considerações são

representadas nos modelos espaciais, em que o RGPM mostra esse caráter mais global entre as variáveis na área de estudo, enquanto o RGP indica um relacionamento significativo em uma escala regional.

A soja, por outro lado, está relacionada à expansão urbana, de acordo com os autores supracitados, nas cidades circunscritas às áreas de plantio no estado de Mato Grosso e nos municípios de Santarém e Paragominas, no Pará. Os resultados dos modelos, de certa forma, vão ao encontro ao dos autores, porém, a espacialidade representada nos testes de hipóteses não capturou, no recorte temporal analisado, tal relacionamento em grandes municípios produtores, como Sorriso e Lucas do Rio Verde, no Norte do estado, e Rondonópolis e Primavera do Leste, no Sudeste.

Os municípios dos estados da Amazônia Ocidental, ainda de acordo com Richards e VanWey (2015), possuem diferentes vetores que impulsionam o crescimento urbano, com o destaque crescente da soja ao longo dos principais eixos de circulação ao longo de Rondônia, assim como a pecuária, o garimpo, e a extração de madeira, etc.

## **CONSIDERAÇÕES FINAIS**

O presente trabalho buscou explorar o relacionamento espacial entre variáveis representativas do processo de urbanização e desmatamento na Amazônia Legal. Ressalta-se novamente que os resultados expressam algumas dimensões que compõem os processos, não o processo em si, devido a complexidade que os caracteriza. Esta complexidade é marcada tanto pelo caráter multidimensional dos processos, como exposto anteriormente, como também por suas diversidades conceituais.

O modelo RGPM apresentou os melhores ajustes em relação ao RGP e RL, no entanto, a LB da variável “Agro\_LT” produziu resultados insignificantes, o que não propiciou investigar padrões espaciais em uma escala diferente do RGP. Por outro lado, o modelo RGP apresentou os padrões espaciais mais significativos do relacionamento entre luzes noturnas e indicadores agropecuários. Tais constatações indicam que os modelos não são concorrentes, e sim complementares para análise exploratória de padrões espaciais.

A existência de relação espacial entre os dados de luzes noturnas e os indicadores agropecuários é caracterizada de acordo com os tipos de commodities na Amazônia Legal. Os resultados apontam que o incremento de luzes noturnas em municípios do Sudoeste de Mato Grosso, no Leste Rondoniense, no Sudeste paraense, no Oeste maranhense e em uma porção expressiva do Tocantins se dá em função do desmatamento para áreas de

pasto. Já no Norte, Nordeste e Sudeste de Mato Grosso, Sul e Oeste do Maranhão e Paragominas, no Pará, a soja é o vetor responsável. A expansão da soja também está relacionada aos municípios com incremento significativo na Amazônia Ocidental.

Os resultados obtidos estão consistentes com a literatura sobre a relação rural-urbana no período marcado pela expansão das atividades agropecuárias em um contexto de modernização das técnicas de produção, circulação e distribuição, o que caracteriza sua realização em diferentes escalas. No entanto, a investigação entre a relação dos dados em outras unidades de análise diferente da do município é uma etapa importante para uma compreensão mais ampla dos processos intermediados.

A inclusão da dinâmica temporal na relação entre luzes noturnas e indicadores agropecuários é outra lacuna importante do trabalho a ser investigada. Relacionar os dados no tempo e no espaço amazônico é de suma importância para buscar compreender como a dinâmica do uso e cobertura da terra no campo está influenciando a produção e organização do espaço urbano.

## REFERÊNCIAS BIBLIOGRÁFICAS

AGUIAR, A. P. D. et al. Spatial statistical analysis of land-use determinants in the Brazilian Amazon: Exploring intra-regional heterogeneity. **Ecological Modelling**, v. 209, n. 2-4, p. 169-188, 2007.

AMARAL, S. et al. DMSP/OLS night-time light imagery for urban population estimates in the Brazilian Amazon, International. **Journal of Remote Sensing**, v. 27, p. 855-870, 2006.

ARRUDA, Z. A. As cidades na região de expansão do agronegócio e as novas territorialidades. **Territorium Terram**, v. 1, n. 1, p. 72-94, 2012.

BECKER, B. K. **Amazônia** São Paulo: Ática, 1990.

\_\_\_\_\_. B. K. **Amazônia: geopolítica na virada do III milênio**. Rio de Janeiro: Garamond, 2004.

\_\_\_\_\_. Geopolítica da Amazônia. *Estudos Avançados*, v. 19, n. 53, p. 71-86, 2005.

\_\_\_\_\_. *A urbe amazônica*. 1. ed. Rio de Janeiro: Garamond, 2013.

BRITO, T. et al. LCA of soybean supply chain produced in the state of Pará, located in the Brazilian Amazon Biome. **Biology and Life Science Forum**, v. 3, n. 11, p. 1-7, 2021.

CÔRTEZ, J. C.; SILVA JÚNIOR, R. D. A interface entre desmatamento e urbanização na Amazônia Brasileira. **Ambiente & Sociedade**, v. 24, p. 1-23, 2021.

CHEN, S. et al. Modeling ESV losses caused by urban expansion using cellular automata and geographically weighted regression. **Science of The Total Environment**, v. 712, p. 1-13, 2020.

DIAS, F. G.; LIMA, A. M. M. As mudanças de cobertura da terra em bacia hidrográfica sob pressão dos sistemas de uso e ocupação do território na Amazônia Oriental. **Revista InterEspaço**, v. 7, p. 1-23, 2021.

FEITOSA, F. F.; MONTEIRO, A. M. V. Vulnerabilidade e modelos de simulação como estratégias mediadoras: contribuição ao debate das mudanças climáticas e ambientais. **Geografia**, v. 37, n. 2, p. 289-305, 2012.

FOTHERINGHAM, A. S. et al. Multiscale Geographically Weighted Regression (MGWR). **Annals of the Association of American Geographers**, v. 107, n. 6, p. 1247-1265, 2017.

HONG, I.; YOO, C. Analyzing spatial variance of Airbnb pricing determinants using Multiscale GWR approach. **Sustainability**, v. 12, p. 1-18, 2020.

IBGE – Instituto Brasileiro de Geografia e Estatística. **Produção Agrícola Municipal**. Rio de Janeiro, 2020. Disponível em: <<https://sidra.ibge.gov.br/Acervo#/S/Q>>. Acessado em: 15 de dezembro de 2021.

INPE – Instituto Nacional de Pesquisas Espaciais. Coordenação Geral de Observação da Terra. Programa de Monitoramento da Amazônia e demais Biomas. **Desmatamento – Amazônia Legal** – Disponível em: <<http://terrabrasilis.dpi.inpe.br/downloads/>>. Acessado em: 15 de dezembro de 2021.

JUSYS, T. Fundamental causes and spatial heterogeneity of deforestation in Legal Amazon. **Applied Geography**, v. 75, p. 188-199, 2016.

KUSCHNIG, N. et al. Spatial spillover effects from agriculture drive deforestation in Mato Grosso, Brazil. **Scientific Reports**, v. 11, p. 1-9, 2021.

LABRUNA, M. B.; PEREIRA, V. Faces da modernização socioespacial das fronteiras capitalistas do agronegócio da Amazônia brasileira: análise dos ajustamentos territoriais da soja no MAPITO e nordeste mato-grossense. **Anais ENANPUR**, v.14, n. 1, p. 1-19, 2011.

LETU, H. et al. Regional-Scale Estimation of Electric Power and Power Plant CO2 Emissions Using Defense Meteorological Satellite Program Operational Linescan System Nighttime Satellite Data. **Environmental Science & Technology Letters**, v. 1 (5), p. 259-265, 2014.

MATOS, P. F.; PESSÔA, V. L. S. A modernização da agricultura no Brasil e os novos usos do território. **GeoUERJ**, v. 2, n. 22, p. 290-322, 2011.

MELLANDER, C. et al. Night-Time Light Data: A Good Proxy Measure for Economic Activity?. **PLOS ONE**, v. 10, 2015.

OSHAN, T. M. et al. Targeting the spatial context of obesity determinants via multiscale geographically weighted regression. **International Journal of Health Geographics**, v. 19, p. 1-17, 2020.

PROJETO MAPBIOMAS – **Coleção 6 (1985 – 2020) da Série Anual de Mapas de Uso e Cobertura de Solo do Brasil**. Disponível em: <<https://mapbiomas.org/>>. Acessado em 1 de dezembro de 2021.

- RICHARDS, P.; VANWEY, L. Where deforestation leads to urbanization: how resource extraction is leading to urban growth in the Brazilian Amazon. **Annals of the Association of American Geographers**, v. 105, n. 4, p. 806-823, 2015.
- SANTOS, A. M. et al. Deforestation drivers in the Brazilian Amazon: assessing new spatial predictors. **Journal of Environmental Management**, v. 294, p. 1-12, 2021.
- SAUER, S.; PIETRAFESA, J. P. Novas fronteiras agrícolas na Amazônia: expansão da soja como expressão das agroestratégias no Pará. **ACTA Geográfica**, Ed. Especial Geografia Agrária, p. 245-264, 2013.
- SHU, S. et al. Multi-scale analysis of spatially varying relationships between agricultural landscape patterns and urbanization using geographically weighted regression. **Applied Geography**, v. 32, n. 2, p. 360-375, 2012.
- SILVA, R. G. C. Amazônia globalizada: da fronteira agrícola ao território do agronegócio – o exemplo de Rondônia. **Confins**, v. 15, n. 23, 2015.
- SILVA, R. A. Centralidade urbano-regional da pecuária de Araguaína-TO: a capital do Boi Gordo?. **Revista de Geografia (Recife)**, v. 34, n. 2, p. 194-215, 2017.
- SONTER, L. J. et al. Mining drives extensive deforestation in the Brazilian Amazon. **Nature Communications**, v. 8, p. 1-7, 2017.
- TRINDADE JÚNIOR, S. C. Pensando a modernização do território e a urbanização difusa na Amazônia. **Mercator**, v. 14, n. 4, p. 93-106, 2015.
- YU, D. et al. Exploring the impact of non-normality on spatial non-stationarity in Geographically Weighted Regression Analyses: Tobacco Outlet Density in New Jersey. **GIScience & Remote Sensing**, v. 46, p. 329-346, 2014.
- ZHANG, Q.; SETO, K. Mapping urbanization dynamics at regional and global scales using multi-temporal DMSP/OLS nighttime light data. **Remote Sensing of Environment**, v. 115, p. 2320-2329, 2011.
- ZHENG, H. et al. Developing non-negative spatial autoregressive models for better exploring relation between nighttime light images and land use types. **Remote Sensing**, v. 12, 2020.