

Análise local dos fatores determinantes na ocorrência de focos de calor por meio da Regressão Geograficamente Ponderada (GWR) no Sul da Amazônia Brasileira.

Maria Lucia Ferreira Barbosa¹

1 Instituto Nacional de Pesquisas Espaciais, Av. dos Astronautas, 1.758, CEP 12227-010, SJC- SP, Brasil, maria.lucia@inpe.br.

Resumo

O fogo não ocorre de maneira natural no bioma úmido da Amazônia e, vários, são os fatores que podem estar relacionados a sua ocorrência. Diante disto, o principal objetivo desta pesquisa foi identificar possíveis fatores determinantes na incidência de focos de calor, no Sul da Amazônia brasileira, a partir de técnicas de análise de dados espaciais de efeito local. Para isso, foi aplicada uma Regressão Linear Múltipla a fim de identificar as variáveis explicativas mais significativas ao modelo e, posteriormente, essas variáveis foram analisadas a partir da Regressão Geograficamente Ponderada. Além disso, foi gerado mapa da Densidade Kernel a fim de evidenciar a distribuição dos focos de calor na área de estudo. As áreas mais afetadas pelo fogo foram as porções leste do Mato Grosso e também o Noroeste e Sudoeste do estado com destaque a região do Parque Nacional do Xingu. Os resultados indicam que a Regressão Geograficamente Ponderada apresentou um melhor ajuste do que a Regressão Múltipla. As variáveis significativas foram: distância a rodovias, distância a áreas de agricultura, % de cobertura florestal e quantidade de biomassa disponível. A distância a agricultura apresentou o maior peso em todos os modelos. Os resultados aqui encontrados são importantes tendo em vista a constante expansão agrícola no Mato Grosso e levantam um alerta a respeito do papel da agricultura na ocorrência de fogo em áreas do seu entorno.

Palavras-chave – Regressão, fogo, Amazônia, Mato Grosso, GWR.

1 INTRODUÇÃO

O fogo ocorre através de três fatores principais: a disponibilidade de combustível, condições climáticas favoráveis e uma fonte de ignição. Em relação aos incêndios florestais, o material combustível está relacionado a quantidade de biomassa disponível

para queima, como folhas, galhos, cascas e outros restos de vegetação (Sullivan et al., 2012). Já as condições climáticas propícias se referem, principalmente, a baixas quantidades de chuvas, altas temperaturas e velocidade dos ventos elevada (Sullivan et al., 2012). A fonte de ignição pode ter origem natural, como a incidência de raios, ou antrópica que pode ocorrer de forma acidental ou está ligada ao uso tradicional do fogo para limpezas de áreas de pastagens, agricultura, entre outros.

No bioma Amazônia, o fogo não ocorre de maneira natural pois mesmo na estação seca existe umidade disponível para as plantas, provenientes da umidade armazenada no solo (Miguez-Macho & Fan, 2012). Portanto, as atividades antrópicas podem ser consideradas o principal fator de ocorrência do fogo na Amazônia, que pode ser agravado por eventos extremos de seca ou outras condições climáticas favoráveis ao fogo (Fonseca et al., 2017).

Diante disto, o estudo dos fatores que determinam o fogo pode ser bastante complicado devido a grande heterogeneidade de relações que podem afetar esta dinâmica. Muitos estudos tentam identificar essa dinâmica de maneira global e isto pode mascarar certas relações a nível local. Assim, o objetivo desta pesquisa foi identificar possíveis fatores determinantes na incidência de focos de calor, no Sul da Amazônia brasileira, a partir de técnicas de análise de dados espaciais de efeito local. E, ainda, explicitar a distribuição espacial desses focos.

2 MATERIAL E MÉTODOS

2.1 Área de estudo

A área de estudo consta na Figura 1. A região compreende a porção referente ao bioma Amazônia localizado no estado do Mato Grosso com uma área que representa a 53,5% do estado.

O bioma Amazônia é caracterizado por duas estações climáticas bem definidas, uma chuvosa que vai de outubro a abril e outra seca que ocorre entre maio e setembro. Além disso, A região está dividida em dois domínios climáticos (Alvares et al. 2013), um predominante, Am (tropical úmido) e outro em menor proporção, Aw (tropical com inverno seco). Os maiores níveis de chuvas anuais no Mato Grosso são registrados na porção amazônica, no Norte do estado (Souza et al. 2013).

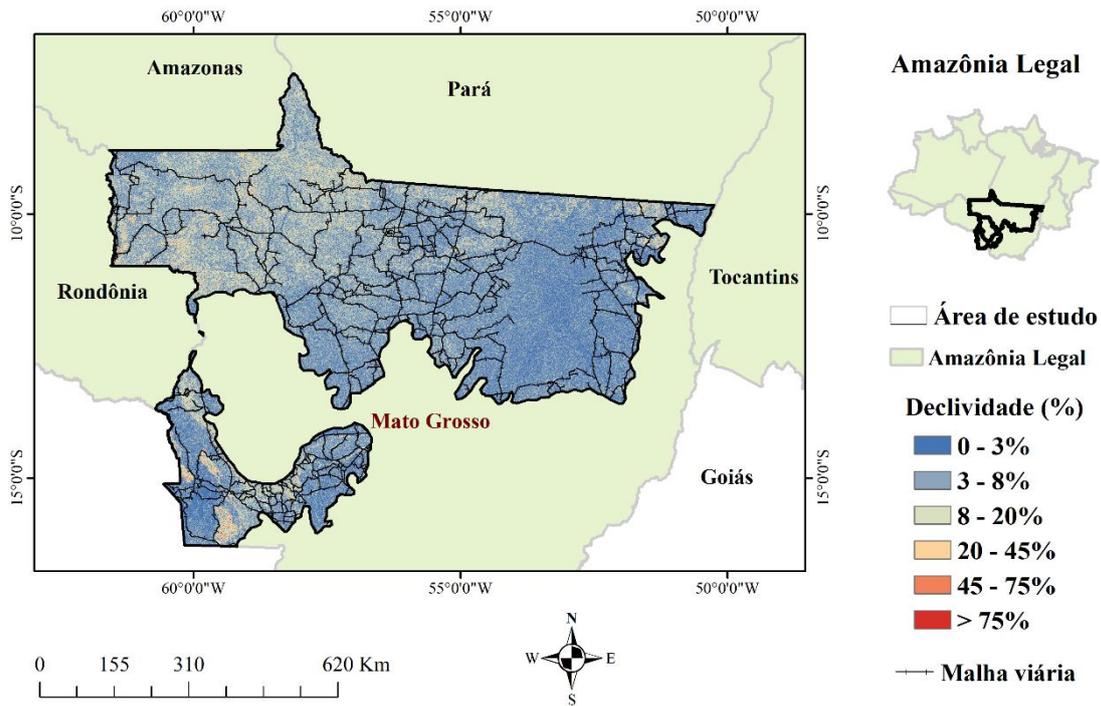


Figura 1. Localização Geográfica da área de estudo.

O Mato Grosso é um estado bastante desmatado, apenas em 2016, 134.048 ha do estado foram desmatados (INPE/PRODES, 2017). O estado compreende parte do que é denominado de arco de desflorestamento, caracterizado pelo intenso avanço agrícola e altos índices de desmatamento. Além disso, o processo de ocupação do estado resultou na concentração de terras sendo o estado do Brasil mais dominado por grandes propriedades (Richards & VanWey, 2016).

2.2 Análise dos dados

Todos os dados utilizados nesta pesquisa foram agregados a uma grade celular de 5x5km. Além disso, os dados foram compatibilizados na projeção cônica de Albers e Datum Sad69. Na tabela 1, consta a descrição das variáveis e a premissa de cada uma em relação aos focos de calor (variável dependente). Ao todo foram utilizadas 12 variáveis explicativas, são elas: quantidade de biomassa, % de cobertura florestal, % de terras indígenas, % de unidades de conservação, declividade (%), acumulado de chuvas e distância euclidiana a rodovias, polos madeireiros, assentamentos, áreas de agricultura e pastagens.

Tabela 1. Resumo das variáveis testadas nos modelos de e sua premissa em relação a variável dependente.

	Variáveis	Descrição	Premissa	Fonte
Dependente	Focos de calor	Log do número de focos por célula	-	Global fire data
Explicativas	Biomassa	Biomassa média (ton/ha)	Grande quantidade de biomassa facilita a ocorrência de focos	Global fire data
	Cobertura florestal	% de cobertura florestal	Áreas cobertas por floresta dificultam a ocorrência de focos	Global fire data
	Rodovias	Distância a rodovias (m)	A proximidade às rodovias facilita a ocorrência de focos	Intermat
	Desmatamento	% de área desmatada	Áreas desmatadas facilitam a ocorrência de focos	PRODES
	Terras Indígenas	% de Terra Indígenas	A presença de terras indígenas dificulta a ocorrência de focos	Mapbiomas
	Unidades de Conservação	% de Unidades de Conservação	A presença de unidades de conservação dificulta a ocorrência de focos	Mapbiomas
	Assentamentos	Distância a áreas de assentamentos (m)	A proximidade a assentamentos pode facilitar a ocorrência de focos	Mapbiomas
	Agricultura	Distância a áreas de agricultura (m)	A proximidade a áreas de agricultura facilita a ocorrência de focos	Mapbiomas
	Pastagem	Distância a áreas de pastagem (m)	A proximidade a áreas de pastagem facilita a ocorrência de focos	Mapbiomas
	Polos madeireiros	Distância a polos madeireiros (m)	A proximidade a polos madeireiros facilita a ocorrência de focos	MMA
	Declividade	Declividade (%)	Declividade alta pode dificultar a ocorrência de focos	SRTM
	Chuvas	Acumulado de chuvas (mm)	Baixas quantidades de chuvas pode facilitar a ocorrência de focos	CHIRPS

MMA = Ministério do meio ambiente, SRTM = Shuttle Radar Topography Mission e Intermat = Instituto de Terras do Mato Grosso

Os dados de focos de calor foram obtidos da plataforma *Global Fire Data (Amazon Dashboard)*. Esta é uma iniciativa que utiliza dados do sensor *Visible Infrared Imaging Radiometer Suite (VIIRS)* e com base na localização, intensidade, duração e taxa de propagação do fogo, cada foco é classificado como foco de desmatamento, foco florestal de sub-bosque, fogo agrícola ou fogo na pastagem. Além disso, a plataforma disponibiliza dados de % de cobertura florestal e quantidade de biomassa também utilizados nesta pesquisa. Para cada variável ligada à distância, foi calculado um mapa da distância euclidiana em cada célula ao ponto mais perto (rodovia, assentamentos, polos madeireiros, agricultura e pastagem).

O período de estudo foi de janeiro a outubro de 2020 devido a disponibilidade de dados do Global Fire Data. Os dados provenientes da plataforma Mapbiomas foram obtidos para o ano de 2019, coleção 5, por serem os dados mais recentes disponíveis até o momento.

2.2.1 Densidade kernel

Com o objetivo de verificar zonas de alta intensidade de focos de calor, foi aplicada uma função do estimador de Densidade Kernel. A distribuição escolhida foi a isotrópica gaussiana pois foi a função que apresentou a melhor suavização das superfícies de intensidade para os dados utilizados. A Densidade Kernel converte dados de pontos em superfície a partir uma função gerada para cada ponto observado com base em uma largura de banda. Esta largura de banda é importante para a confiabilidade dos resultados e por isso optou-se pelo uso do Kernel adaptativo. Este método utiliza uma largura

diferente para cada função com base no número de pontos observados naquele local e com isso elimina-se o viés do operador nos resultados.

O mapa gerado a partir do estimador Kernel possui resolução de 375 metros e foi classificado em 5 classes, de acordo com sua cor e tonalidade, são elas: muito baixa (branco), baixa (azul), média (amarelo), alta (laranja) e muito alta (vermelho). O mapa foi gerado a partir da função *Kernel Density* disponível no software *Arcgis 10.5*.

2.2.2 Regressão Linear Múltipla

O ajuste de um modelo de regressão permite previsão de comportamentos da variável dependente com base em sua associação com uma ou mais variáveis a partir do grau de correlação entre as mesmas. A regressão linear múltipla é utilizada quando se admite que a variável resposta seja função de mais de uma variável explicativa. Sua função é dada por:

$$Y_i = \beta_0 + \beta_1 X_{i1} + \beta_2 X_{i2} + \dots + \beta_p X_{ip} + \varepsilon_i \quad (1)$$

em que Y_i é o valor da variável resposta na i -ésima observação, β_0, \dots, β_p são parâmetros do modelo, X_{i1}, \dots, X_{ip} são os valores das variáveis preditoras na i -ésima observação, ξ_i é um termo de erro aleatório com distribuição normal, média zero e variância constante σ^2 ($E(\xi_i) = 0$ e $\sigma^2(\xi_i) = \sigma^2$).

Para utilizar a análise de regressão, é preciso obedecer a algumas premissas, são elas: distribuição normal dos resíduos, linearidade entre as variáveis, independência entre as observações, homoscedasticidade da variância dos resíduos e garantia de não multicolinearidade entre as variáveis explicativas. Para garantir a linearidade entre as relações, os dados de focos de calor foram transformados a partir da aplicação do logaritmo de base 10. Além disso, foram aplicados os testes de *Jarque-Bera* para atestar a normalidade dos dados, *Breusch-Pagan* para avaliar a homoscedasticidade da variância, o índice de associação local de Moran para avaliar a dependência espacial dos dados e, por fim, foi utilizado o Fator de inflação da variância (VIF) para garantir que não haja variáveis altamente correlacionadas no modelo.

A partir de análise exploratória da regressão, as variáveis foram combinadas a fim de determinar as variáveis que melhor explicam a ocorrência de focos, apenas as variáveis significativas foram utilizadas no modelo final. Além disso, a partir dos indícios de dependência espacial dos dados, foi aplicada a Regressão Geograficamente Ponderada,

explicada em mais detalhes a seguir. A adequação dos modelos foi verificada a partir da análise dos resíduos e do critério de informação de Akaike (AIC) já que o R^2 não é uma variável confiável para comparação dos modelos. O menor valor de AIC indica um melhor ajuste do modelo.

2.2.3 Regressão Geograficamente Ponderada (GWR)

Os modelos de regressão espacial podem variar de acordo como o interesse de estudo, e podem ser aplicados com efeito espacial global e efeito espacial local. Levando em consideração o caráter complexo da modelagem da incidência dos focos de calor, foi utilizado nesta pesquisa o modelo espacial de efeito local a partir da Regressão Geograficamente Ponderada (GWR).

A GWR possui como pressuposto a heterogeneidade espacial e que as relações entre as variáveis assumem padrões regionalizados. Nesta técnica, é aplicada uma regressão local para cada evento observado com base em uma função Kernel e um número de vizinhos. Da mesma forma que para o mapa de densidade, neste caso, também optou-se pela utilização do Kernel adaptativo. O número de vizinhos a ser considerado pode ser estipulado pelo operador ou calculado com base no método da validação cruzada ou do critério de informação Akaike corrigido (AICc). O método escolhido foi o AICc e todas as análises de regressão foram realizadas no software *Arcgis* 10.5.

2.2.4 Indicador local de associação espacial (LISA)

O estimador de autocorrelação espacial de Moran (I), fornece um valor global como medida de associação espacial, porém, muitas vezes, é necessário entender esses padrões em escala local. Diante disto, o indicador local de associação espacial (LISA) fornece um valor específico para cada objeto e permite identificar o padrão espacial dessa dependência.

O LISA é a decomposição do índice global de Moran e permite a identificação de objetos com valores de atributos semelhantes. No LISA, o índice local é calculado a partir do produto dos desvios em relação a média em que valores significativamente altos sugerem alta probabilidade de que exista dependência espacial tanto para regiões com altos valores associados como com baixos valores. A significância dos valores calculados, é obtida através da construção de uma pseudo-distribuição através de permutação. No presente estudo foi utilizado 999 permutações para geração da distribuição. O LISA foi aplicado

para os resíduos da Regressão Linear Múltipla e para a Regressão Geograficamente Ponderada. Toda a análise foi realizada no software Geoda 1.16.

3 RESULTADOS E DISCUSSÃO

3.1 Distribuição espacial dos focos de calor

Ato todo, foram contabilizados até outubro de 2020, 299.729 focos de calor na Amazônia do estado do Mato Grosso. Na Figura 2, é possível observar o padrão espacial dos focos de calor na região de estudo. As manchas de cor laranja e vermelha, que representam pontos de alta densidade de focos, estão concentradas na porção leste do Mato Grosso e também aparecem no Noroeste e Sudoeste do estado. Portanto, em certos pontos existem indícios de que haja associação espacial entre os focos de calor.

Alguns desses pontos de alta intensidade estão localizados próximos ou dentro dos limites do Parque Indígena do Xingu (centro-leste do estado), que até setembro de 2020 era a Terra Indígena com maior número de focos no país (INPE, 2020). A estação seca prolongada este ano na região, aliada a pressão pelo desmatamento e falta de fiscalização por parte do governo podem explicar a grave situação das queimadas e incêndios florestais no Parque do Xingu. Além disso, o Parque do Xingu tem em seu entorno grandes fazendas ligadas ao agronegócio (Menezes, 2008) que aumentam a vulnerabilidade ao desmatamento e ao avanço do fogo.

Outros agrupamentos de focos podem ser identificados na fronteira com Pará (porção Nordeste) e com Rondônia (porção Noroeste). Estes estados sofrem com altos números de focos de calor e de desmatamento, além disso, quase toda a região da Amazônia no estado compreende o chamado “arco do desmatamento” que pode facilitar a ocorrência de queimadas e incêndios.

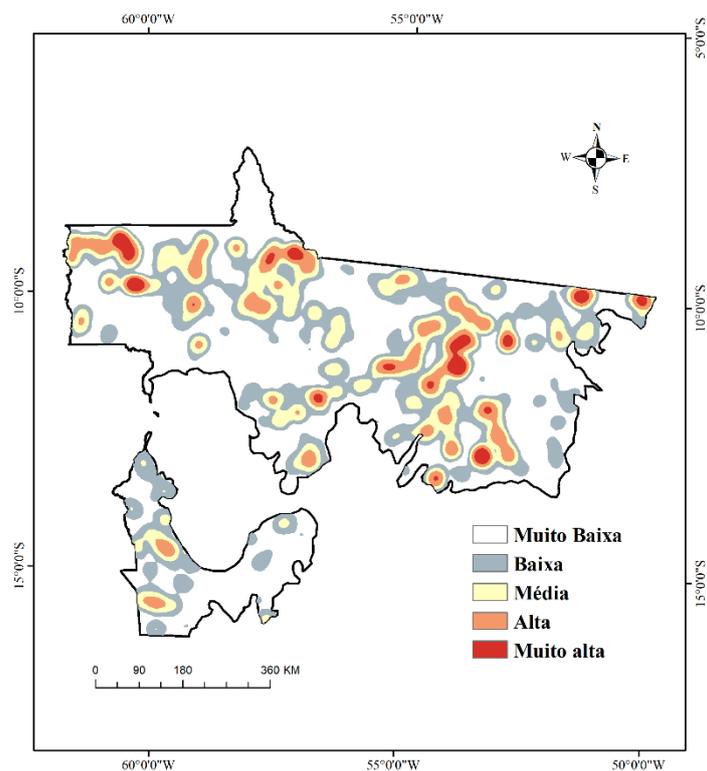


Figura 2. Mapa da densidade kernel dos focos de calor.

3.2 Regressão Linear Múltipla

As variáveis explicativas significativas estão descritas na Tabela 2, foram elas: distância a áreas de agricultura, distância a rodovias, % de cobertura florestal e quantidade de biomassa. A partir dos coeficientes da regressão (Betas), é possível perceber que a variável distância a agricultura foi a que apresentou o maior peso no modelo, enquanto que a biomassa foi a que apresentou o menor peso.

O teste de multicolinearidade demonstrou que não há problemas de correlação entre as variáveis significativas ($VIF > 7,5$), além disso, o R^2 obtido na regressão linear múltipla foi de 0,47. O valor AIC para o modelo de regressão múltipla foi de 28823,790203.

Tabela 2. Significância e multicolinearidade das variáveis explicativas significativas. *95% de confiança.

Variável	Betas	Estatística t	P-valor	VIF
Intercepto	0,097930	16,995364	0,00000*	-
Distância a agricultura	-0,34110	-6,369262	0,00000*	1,005467
Distância a rodovias	0,25011	2,009855	0,00000*	1,000503
% de cobertura florestal	0,00432	20,953182	0,04450*	3,292131
Biomassa	0,00429	54,365796	0,00000*	3,202186

A partir da análise dos resíduos (Figura 3), é possível observar autocorrelação espacial significativa em diversas regiões da área de estudo. As manchas em vermelho no mapa a esquerda indicam agrupamentos com altos valores residuais enquanto que as manchas em azul indicam o inverso, ou seja, agrupamentos com valores baixos dos resíduos. O mapa a direita indica as zonas onde a autocorrelação espacial foi significativa. Áreas com altos valores dos resíduos (em vermelho) foram, em maioria, significativas a um nível de 99,9% de confiança (p -valor = 0,001). O resultado da pseudo significância foi de 0,001, baseado em 999 permutações. Apesar disso, o índice global de Moran (0,272) é considerado baixo e indica pouca associação espacial. O fato de as análises terem sido feitas em grade celular pode mascarar algumas dessas relações e, portanto, os resultados devem ser interpretados com cautela.

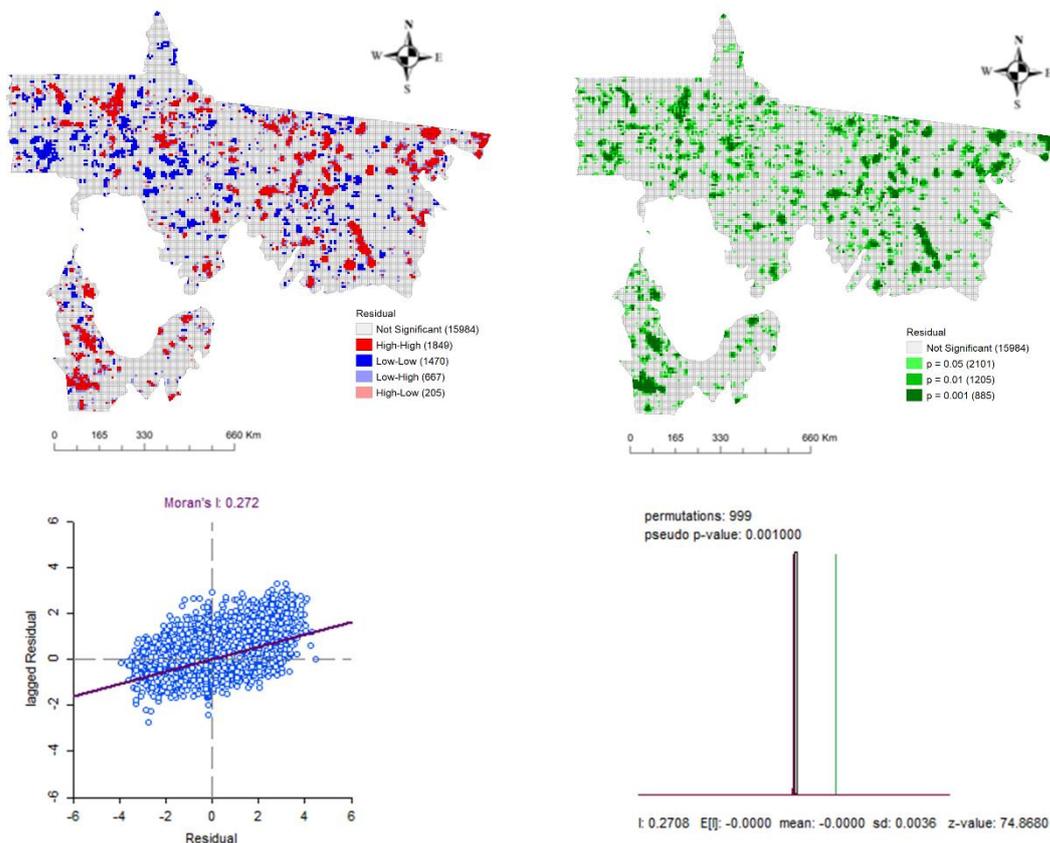


Figura 3. Análise dos resíduos da regressão múltipla através de indicadores locais de associação espacial (LISA) do teste de Moran.

3.3 Regressão geograficamente ponderada (GWR)

A partir das variáveis significativas apontadas na Tabela 2, foi aplicada a GWR e os resultados estão apresentados na Figura 4. A partir do mapa de R^2 local, é possível

observar que os focos de calor puderam ser explicados pelas variáveis selecionadas em no mínimo 15% ($R^2 = 0,1522$) e no máximo em 76% ($R^2 = 0,7676$) a depender da localidade. O valor de AIC para o GWR foi de 27589,127597, este valor foi menor do que o apresentado pela regressão múltipla, indicando um melhor ajuste para este modelo.

As maiores relações encontradas (manchas vermelhas) coincidem com os agrupamentos de alta e muito alta densidade de focos (Figura 2), exceto pela porção sudoeste onde as variáveis apresentaram baixo poder explicativo para a ocorrência dos focos. Além disso, os locais com maiores valores de R^2 são, em maioria, áreas de floresta e agropecuária que são áreas bastante atingidas por focos. Os resultados aqui encontrados apontam a alta relação de focos em áreas próximas a agricultura, rodovias e com biomassa disponível.

O estado do Mato Grosso é considerado um importante local na expansão agrícola brasileira (Arvor et al., 2012). Assim, a conversão de florestas naturais em áreas de agricultura e pastagem é bastante comum em um estado que é o maior produtor de soja do Brasil (Embrapa, 2020). A agricultura está diretamente relacionada ao uso do fogo e este pode se espalhar para áreas de floresta devido aos efeitos da fragmentação e da biomassa disponível. Da mesma forma, as rodovias fragmentam as florestas e podem torna-las mais susceptíveis a entrada do fogo (Silva Junior et al., 2018)

Já a quantidade de biomassa está relacionada ao poder de propagação do fogo, portanto, uma área com alta quantidade de biomassa disponível teria maior probabilidade de apresentar um alto número de focos de calor caso tenha uma fonte de ignição (por exemplo, proveniente de áreas de agricultura). Fernandes et al., (2014) concluíram que a fonte de ignição e o combustível disponível podem alterar consideravelmente a dinâmica de fogo, independente dos fatores climáticos em estudo realizado em Portugal.

Apesar da não significância da variável chuva, esta pode influenciar na quantidade de biomassa disponível para o fogo à medida que, em condições de pouca chuva, mantém a vegetação mais seca e favorece a perda de folhas e galhos que podem servir como combustível para o fogo.

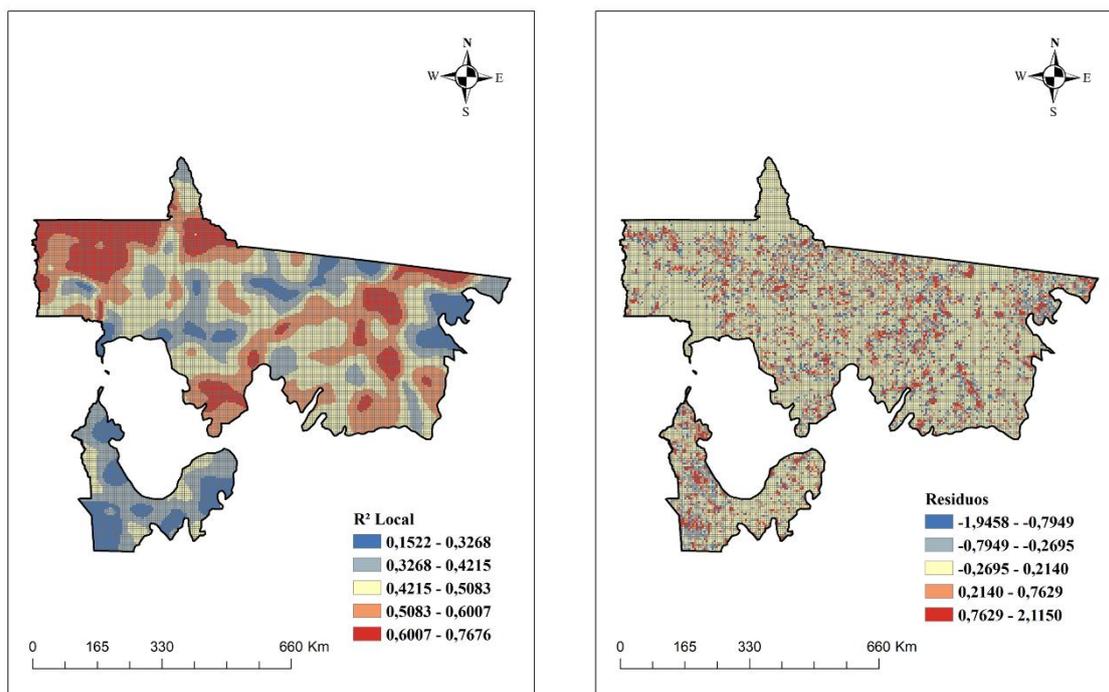


Figura 4. R² local (a esquerda) e resíduos (a direita) provenientes da regressão geograficamente ponderada (GWR).

Na Tabela 3 estão descritos os betas de 10 pixels amostrados na área de estudo para cada variável significativa. O peso de cada variável ao longo da área de estudo é bastante heterogêneo em que, de forma geral, os maiores pesos foram associados aos maiores R². Da mesma forma que na análise de Regressão Múltipla, a distância a agricultura foi a variável de maior peso nos modelos, porém a variável de menor peso foi a % de cobertura florestal.

Esses resultados confirmam a necessidade de avaliação local ao estudar ocorrência de fogo já que diferentes fatores podem explicar o mesmo e estes fatores podem ter pesos diferentes em cada local.

Tabela 3. Coeficientes da regressão em 10 células para as variáveis significativas na GWR.

R ²	Betas			
	Distância a agricultura	Distância a rodovias	% de cobertura florestal	Biomassa
0,76	-0,58670	0,47992	0,04552	0,05621
0,76	-0,56012	0,35987	0,05019	0,05632
0,73	-0,55072	0,22178	0,00315	0,04301
0,71	-0,20023	0,54231	0,00398	0,04298
0,70	-0,14756	0,02000	0,00285	0,03521
0,69	-0,47250	0,04535	0,00254	0,01200
0,67	-0,47569	0,02774	0,00482	0,00845
0,65	-0,18574	0,01200	0,00418	0,00578
0,50	-0,17456	0,01254	0,00189	0,00401
0,49	-0,01000	0,00102	0,00100	0,00435

A análise dos resíduos do GWR, por meio do LISA, está apresentada na Figura 5. O índice global de Moran (0,166), mais próximo de zero, foi ainda menor do que o obtido na Regressão Linear Múltipla. Ainda assim, é possível observar no mapa dependência espacial significativa em algumas regiões da área de estudo e, da mesma forma que na Regressão Múltipla, o resultado da pseudo significância foi de 0,001 (significativo). Sugere-se o uso de outras técnicas de Regressão espacial a fim de identificar como a variável espacial se comporta em relação ao conjunto de dados utilizados.

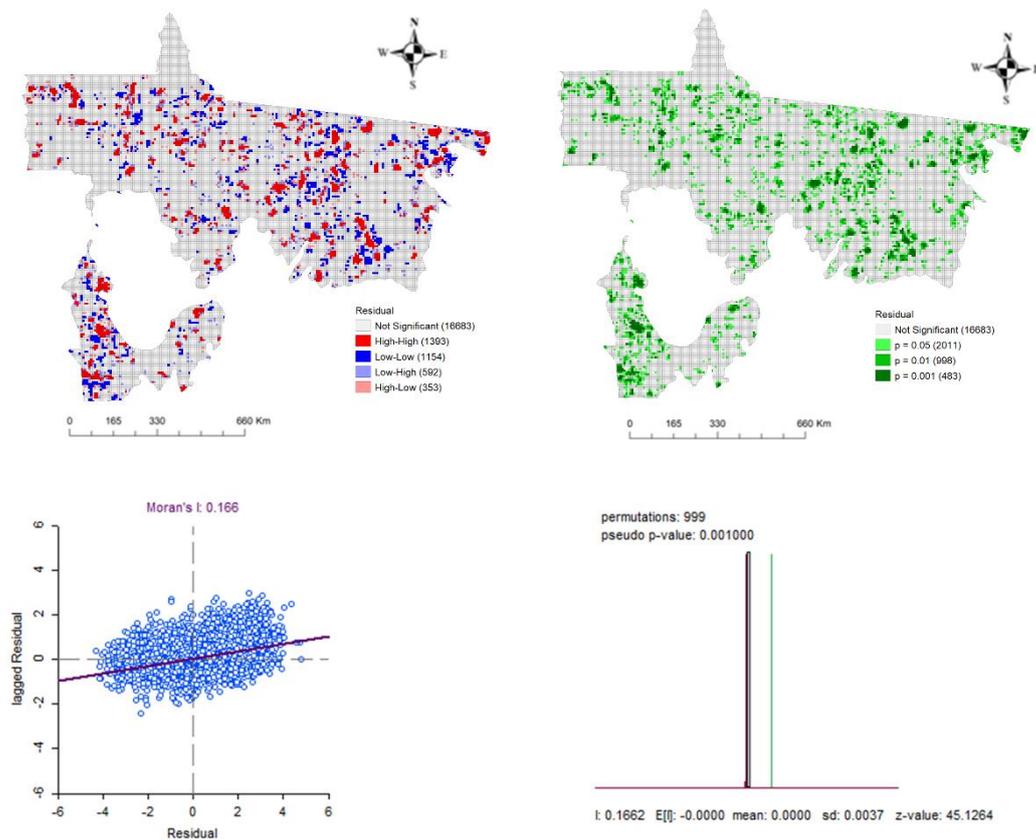


Figura 5. Análise dos resíduos da regressão geograficamente ponderada (GWR) através de indicadores locais de associação espacial (LISA) do teste de Moran.

4 CONCLUSÃO

A técnica de Regressão Geograficamente Ponderada se mostrou com um melhor ajuste do que quando comparada a Regressão Múltipla tradicional. Isto indica que o fator espacial e também local deve ser levado em consideração em estudos sobre o fogo.

Os focos de calor na Amazônia do Mato Grosso puderam ser explicados em maior e menor escala pelas seguintes variáveis: distância a rodovias e áreas de agricultura, biomassa disponível e % de cobertura florestal. As chuvas não foram significativas no modelo, mas outras variáveis climáticas devem ser consideradas em modelos futuros. Além disso, uma análise voltada para os focos em áreas de floresta e durante a estação seca pode ser importante para um melhor entendimento dos fatores que determinam o fogo nas florestas amazônicas. Um outro ponto seria uma análise temporal desses fatores a fim de determinar se os mesmos mudam em anos de clima extremo, por exemplo.

As áreas mais afetadas pelo fogo foram as porções Nordeste, Noroeste e Centro-Leste do estado. O Parque Nacional do Xingu apresentou alto número de focos e alta relação com as variáveis explicativas selecionadas no modelo final. Além do uso tradicional, o parque tem em seu entorno diversas fazendas ligadas ao agronegócio o que é preocupante para a conservação das florestas ali existentes.

Determinar os fatores de ocorrência de focos de calor pode ser bastante complexo e esta dinâmica deve ser levada em consideração em um contexto local. Os resultados aqui encontrados são importantes tendo em vista a constante expansão agrícola no Mato Grosso e levantam um alerta a respeito do papel da agricultura na ocorrência de fogo em áreas do seu entorno.

REFERÊNCIAS BIBLIOGRÁFICAS

Alvares CA, Stape JL, Sentelhas PC, et al (2013) Köppen's climate classification map for Brazil. *Meteorol Zeitschrift* 22:711–728. doi: 10.1127/0941-2948/2013/0507

Arvor, D., Meirelles, M., Dubreuil, V., Begue, A., Shimabukuro, Y.E., 2012. Analyzing the agricultural transition in Mato Grosso, Brazil, using satellite-derived indices. *Appl. Geogr.* 32 (2), 702–713. <https://doi.org/10.1016/j.apgeog.2011.08.007>.

Empresa Brasileira de Pesquisa Agropecuária – EMBRAPA. Embrapa Soja. Disponível em: <<https://www.embrapa.br/soja/cultivos/soja1/dados-economicos>>. Acesso em: dez de 2020.

Fernandes, P. M., Loureiro, C., Guiomar, N., Pezzatti, G. B., Manso, F. T., & Lopes, L. (2014). *The dynamics and drivers of fuel and fire in the Portuguese public forest. Journal of Environmental Management*, 146, 373–382. doi:10.1016/j.jenvman.2014.07.049

Fonseca, M. G., Anderson, L. O., Arai, E., Shimabukuro, Y. E., Xaud, H. A., Xaud, M. R., ... & Aragão, L. E. (2017). Climatic and anthropogenic drivers of northern Amazon fires during the 2015–2016 El Niño event. *Ecological applications*, 27(8), 2514-2527.

Instituto Nacional de Pesquisas Espaciais (INPE), 2017. Projeto PRODES – Monitoramento da Floresta Amazônica Brasileira por Satélite. INPE, São José dos Campos. <http://www.obt.inpe.br/prodes/index.php>. Acesso em: dez de 2020.

Instituto Nacional de Pesquisas Espaciais (INPE), 2020. Banco de dados de queimadas. Disponível em: <<http://queimadas.dgi.inpe.br/queimadas/bdqueimadas/>>.

Menezes, M. L. P. (2009). Parque Indígena do Xingu: efeitos do modo de vida urbano e da urbanização no território indígena. *Novos Cadernos NAEA*, 11(2).

Miguez-Macho, G., & Fan, Y. (2012). The role of groundwater in the Amazon water cycle: 2. Influence on seasonal soil moisture and evapotranspiration. *Journal of Geophysical Research: Atmospheres*, 117(D15).

Richards, P. D., & VanWey, L. (2016). Farm-scale distribution of deforestation and remaining forest cover in Mato Grosso. *Nature Climate Change*, 6(4), 418-425.

Silva Junior, C., Aragão, L., Fonseca, M., Almeida, C., Vedovato, L., & Anderson, L. (2018). Deforestation-Induced Fragmentation Increases Forest Fire Occurrence in Central Brazilian Amazonia. *Forests*, 9(6), 305.

Souza A.P. De, Lima L, Zamadei T, et al (2013). Classificação climática e balanço hídrico climatológico no estado de Mato Grosso. *Nativa* 1:34–43. doi: 10.14583/2318-7670.v01n01a07.

Sullivan, A. L., McCaw, W. L., Cruz, M. G., Matthews, S., & Ellis, P. F. (2012). Fuel, fire weather and fire behaviour in Australian ecosystems. *Flammable Australia: fire regimes, biodiversity and ecosystems in a changing world*, 51-77.