



Uso do modelo de Regressão Espacial no estudo das relações entre ocorrência de queimadas e fragmentação da paisagem

Use of Spatial Regression model to study the relationship between fire occurrence and landscape fragmentation

Thais Pereira de Medeiros ¹

Instituto Nacional de Pesquisas Espaciais (INPE), Programa de Pós Graduação em Sensoriamento Remoto

Resumo: As queimadas e os incêndios florestais têm se tornado umas das maiores preocupações mundiais nos últimos anos, dado o aumento da recorrência desses eventos e sua contribuição para as emissões de CO² na atmosfera. Além disso, a ocorrência, intensidade e incidência do fogo varia com o nível de perda de habitat, fragmentação da paisagem e mudanças de uso e cobertura da terra. Neste sentido, o trabalho teve por objetivo investigar a associação entre a ocorrência de queimadas e as variáveis de fragmentação da paisagem no Estado do Pará para o ano de 2020, a partir do modelo de regressão espacial local, Geographically Weighted Regression (GWR). Utilizou-se como unidade amostral do trabalho uma grade regular celular de 35km e para aplicação do GWR foi definido como variável resposta os focos de calor e como variáveis explicativas métricas de paisagem (PLAND, MPA, NP, ED e TCA). O método GWR ajusta um modelo de regressão a cada ponto observado, ponderando todas as demais observações como função de distância a este ponto e foi interessante porque possibilitou levantar alguns questionamentos sobre a ocorrência de queimadas, questionamentos estes que serão alvo de estudo em trabalhos futuros. De modo geral, as análises realizadas no trabalho indicam que paisagens mais fragmentadas, com manchas pequenas e alta densidade de borda, tendem a ser mais vulneráveis aos distúrbios antrópicos (como é o caso do fogo), do que paisagens florestais intactas e contínuas.

Palavras-chave: Queimadas. Incêndios florestais. Mudanças de uso e cobertura da terra. Fragmentação da paisagem. Geographically Weighted Regression.

Abstract: Fires and forest fires have become one of the biggest concerns in the world in recent years, given the increase in the recurrence of these events and their contribution to CO² emissions into the atmosphere. Furthermore, the occurrence, intensity, and incidence of fire vary with the level of habitat loss, landscape fragmentation, and changes in land use and land cover. In this sense, the study aimed to investigate the association between the occurrence of fires and landscape fragmentation variables in the State of Pará for the year 2020, using the Geographically Weighted Regression (GWR), a local spatial regression model. A 35km regular cellular grid was used as the work sampling unit, and for the application of GWR, it was defined as the dependent variable to hot spots and as independent variables to landscape metrics (PLAND, MPA, NP, ED, and TCA). The GWR method adjusts a regression model to each observed point, weighting all other observations as a function of distance to this point, and it was interesting because it made it possible to raise some questions about the occurrence of fires, which will be studied in the future works. In summary, the analyzes carried out indicate that more fragmented landscapes, with small patches and high edge density, tend to be more vulnerable to anthropic disturbances (such as fires) than intact and continuous forest landscapes.

Keywords: Fires. Forest Fires. Land-use and Land-cover changes. Landscape Fragmentation. Geographically Weighted Regression.

1. INTRODUÇÃO

O Brasil se comprometeu internacionalmente, perante o Acordo de Paris, por meio da Contribuição Nacionalmente Determinada (NDC), a reflorestar 12 milhões de hectares de florestas até 2030, bem como reduzir as emissões líquidas totais de gases de efeito estufa em 37% até 2025 (BRASIL, 2017). Entretanto, um dos grandes desafios para o sucesso da restauração ecológica dos biomas e ecossistemas é sua relação com as queimadas e os incêndios florestais, visto que a configuração e as características da paisagem influenciam a sua propagação.

As queimadas e os incêndios florestais têm se tornado umas das maiores preocupações mundiais nos últimos anos, dado o aumento da recorrência desses eventos e sua contribuição para as emissões de CO² na atmosfera, contribuindo significativamente para as alterações climáticas globais (ANDERSON et al, 2005; BARLOW et al., 2012; ARAGÃO et al, 2018; SILVA JUNIOR et al, 2019). Estudos demonstram que todos os anos, principalmente durante o período de seca, milhares de hectares dos biomas e ecossistemas estão sendo queimados e, com isso, submetidos a danos irreparáveis (PIVELLO et al., 2021). A ocorrência e intensidade do fogo é influenciada por diversos fatores, principalmente pelas mudanças de uso e cobertura da terra e condições climáticas (PIVELLO et al., 2021; BURTON et al., 2020). Os impactos negativos relacionados ao fogo são inúmeros, podendo desestabilizar os estoques de carbono dos ecossistemas terrestres, promover perdas econômicas, alterar a composição, estrutura e funcionamento da floresta, impactar a qualidade do ar, ocasionar problemas de saúde respiratória na população (ANDERSON et al., 2011; BARLOW et al., 2012; CAMPANHARO et al, 2019) e, também, causar danos à conservação da biodiversidade (CHUVIECO et al., 2014; VEENENDAAL et. al, 2015). Além disso, a sucessão intensa de focos de calor podem alterar as taxas de infiltração e a evapotranspiração, aumentando, conseqüentemente, a susceptibilidade da área à erosão (SHIMABUKURO et al., 2020).

Na Amazônia, a ocorrência de queimadas está associada à atividades antrópicas, principalmente para limpeza de áreas agrícolas, formação de pastagens (FEARNSIDE, 2005; MORTON et. al, 2008; MULLER, 2020) ou para a prática de desmatamento (ARAGÃO et al, 2008; DAVIDSON et. al, 2012; JUÁREZ-OROZCO et. al, 2017). O desmatamento, além de apresentar taxas com acentuado aumento, exerce influência direta no regime e dinâmica de fogo por conta das fontes de ignição ocasionadas pelos processos de degradação (ALENCAR et al., 2015). Uma vez iniciado, o fogo pode se tornar generalizado e incontrolável, passando a ser considerado como incêndio florestal à medida que adentra para as áreas de bordas das florestas. Tal processo pode provocar o desmatamento adicional e fragmentar a floresta remanescente (ARMENTERAS et al., 2013).

A ocorrência, intensidade e incidência do fogo varia também com o nível de perda de habitat e fragmentação da paisagem. A fragmentação florestal é caracterizada por uma ruptura da unidade de paisagem (METZGER, 2001, 2003), e encontra-se entre as mais graves ameaças para a manutenção dos ecossistemas e da diversidade biológica (PRIMACK; RODRIGUES, 2001). Essa fragmentação é responsável por propiciar o aumento do efeito de borda e, conseqüentemente, a intensificação da influência dos fatores externos. As bordas florestais são originadas em virtude das práticas de desmatamento e pela conversão de vegetação nativa em plantações de culturas agrícolas e pastagens. Além disso, nas áreas de borda são observadas o aumento da luminosidade, a diminuição da umidade e o maior número de mortalidade de árvores quando comparado com o interior da floresta. Ademais, é comum a presença de alta densidade de cipós e de gramíneas exóticas oriundas das pastagens vizinhas. Essa intensificação da influência dos efeitos externos associada às mudanças microclimáticas (aumento da temperatura do ar e propagação da estação seca) torna a biomassa mais inflamável, provocando o aumento das queimadas (SILVA JUNIOR, et al., 2018; ARMENTERAS, 2013).

O aumento descontrolado do fogo é extremamente perigoso porque pode afetar a regeneração da floresta, através da alteração dos ecossistemas e, também do isolamento das populações, tornando as espécies tolerantes ao fogo mais abundantes e aumentando a probabilidade de que espécies vulneráveis ao fogo possam desaparecer. Assim, o monitoramento e entendimento dessa dinâmica é essencial para a melhor

compreensão acerca da interação dos processos ecológicos com os impactos provenientes das atividades humanas, subsidiando a previsão de tendências futuras e a formulação de novas políticas públicas (GIGLIO et al., 2018, CHUVIECO et al., 2019). Entretanto, tal quantificação não é feita de forma sistemática, há uma alta complexidade desde a coleta de dados até o desenvolvimento de uma metodologia que acomode todas estas informações de modo a gerar um dado quantitativo e explícito destes impactos (ANDERSON et al., 2020).

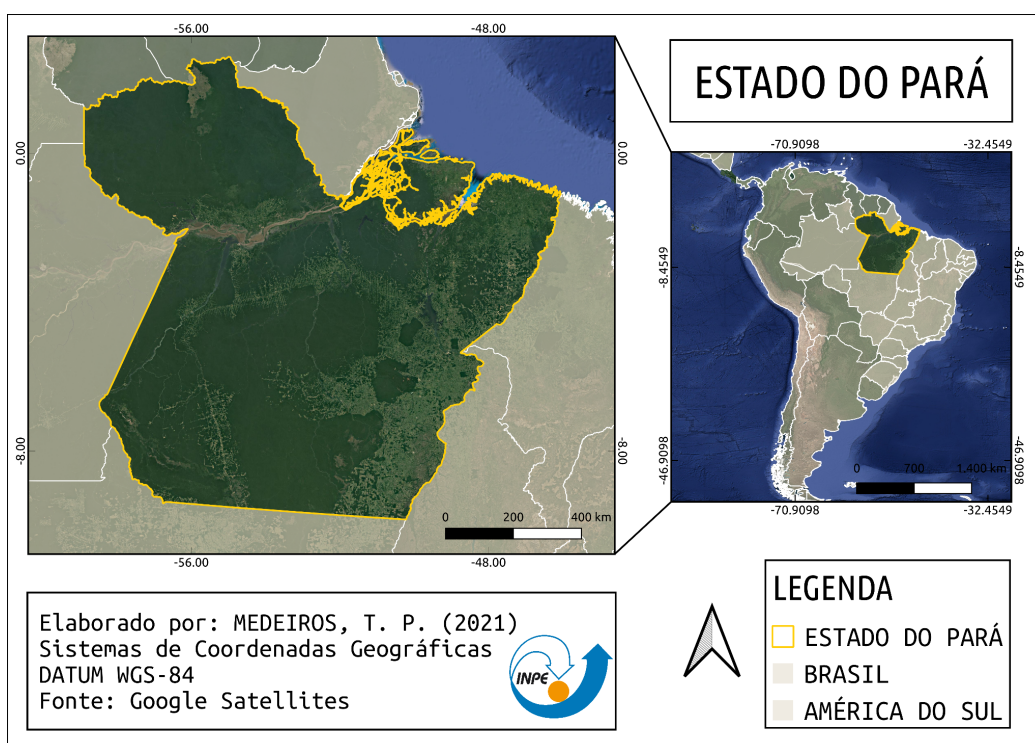
Neste sentido, o trabalho teve por objetivo investigar a associação entre a ocorrência de queimadas e as variáveis de fragmentação da paisagem no Estado do Pará para o ano de 2020. Muitos estudos utilizam dos Modelos de Regressão Linear para analisar a relação entre uma variável resposta e uma ou mais variáveis explicativas, de modo a prever o comportamento da variável dependente e também para entender as causas de variação de um fenômeno. No entanto, o uso de Modelos de Regressão Espacial têm apresentado resultados promissores, pois permite a incorporação da componente espacial na variável dependente Y (OOM; PEREIRA, 2013).

2. MATERIAIS E MÉTODOS

2.1. Área de estudo

A área de estudo compreendeu o estado do Pará, localizado dentro do domínio do bioma Amazônico (Figura 1), tendo como capital o município de Belém e, segundo os dados do IBGE, um Índice de Desenvolvimento Humano de 0,646 (2010). As atividades econômicas do estado concentram-se, atualmente, no setor de extrativismo mineral e madeireiro e, também na expansão da agricultura para plantação e produção de soja. Além disso, as elevadas taxas de crescimento populacional e o alto grau de urbanização da região conferem ao estado o título de estado mais populoso da região Norte (RIBEIRO et al., 2018). Pará está entre os estados da Amazônia Legal que vêm apresentando aumento significativo no número de queimadas, afetando áreas sensíveis, como por exemplo, as áreas protegidas (SANTOS et al., 2021).

Figura 1 - Mapa de localização da área de estudo.



Fonte: os autores.

2.2. Coleta dos dados

Primeiramente, foram extraídos do Banco de Dados de Queimadas do INPE, em formato shapefile, os dados de focos de calor para o Estado do Pará para o ano de 2020, utilizando como base o satélite NPP-375. O S-NPP (*Suomi-National Polar-orbiting Partnership*) é o primeiro satélite da nova geração de satélites de órbita polar da série JPSS (*Joint Polar Satellite System*), lançado em 2011 e, apresenta uma resolução espacial de 375 metros. Além disso, foram obtidos os dados de uso e cobertura da terra a partir da plataforma do MapBiomias, em formato raster para o ano de 2020, produzidos utilizando mosaicos de imagens do satélite LANDSAT 5, 7 e 8, sensores *Thematic Mapper (TM)*, *Enhanced Thematic Mapper (ETM+)* e *Operational Land Imager/Thermal Infrared Sensor (OLI-TIRS)*, com tempo de revisita de 16 dias e resolução espacial de 30 metros. Todo o mapeamento do MapBiomias é feito utilizando o processo de classificação de imagens de pixel-a-pixel, com algoritmos de *machine learning*, através da plataforma *Google Earth Engine* que oferece imensa capacidade de processamento na nuvem.

2.3. Procedimentos metodológicos

Primeiramente, foi feito o recorte dos dados para a área de interesse (Estado do Pará) e, posteriormente, a criação da grade celular regular de 35 km². Em sequência, os dados de focos de calor foram agregados para a grade celular regular a partir da função de Preenchimento de Atributos disponível no software TerraView. Com relação aos dados de uso e cobertura da terra foi realizada uma reclassificação das classes espectrais, onde o seguinte agrupamento foi aplicado:

Tabela 1 - Reclassificação dos dados de uso e cobertura advindos do MapBiomias.

ID	Classe	Classe agrupada	ID MapBiomias
1	Floresta	Formação florestal	3
		Formação savânica	12
		Mangue	21
		Silvicultura	4
2	Não Floresta	Formação campestre	12
		Mosaico de agricultura e pastagem	21
		Mineração	30
		Soja	39
		Outras lavouras perenes	48
		Campo alagado e área pantanosa	11
		Pastagem	15
		Praia, duna	23
		Área urbanizada	24
		Outras áreas não vegetadas	25
		Apicum	32
		Raio, lago, oceano	33
		Outras lavouras temporárias	41

Fonte: MapBiomias.

Para analisar o comportamento dos focos de calor em relação às paisagens fragmentadas foi feita a definição e extração das métricas de paisagem a partir do mapa binário (floresta / não floresta), obtido com base nos dados de uso e cobertura da terra. Compreender a estrutura da paisagem é importante para identificação do padrão espacial dos elementos que a compõem e, também para entender a conexão entre os diferentes ecossistemas, avaliando a relação entre eles a partir de cálculos como medida, número, tamanho e forma (FORMAN; GODRON, 1986). As paisagens fragmentadas diferem-se no tamanho e na forma dos fragmentos e em sua configuração espacial (BENNET; SAUNDERS, 2010). Neste sentido, para quantificar a estrutura espacial da paisagem faz-se uso das métricas de paisagem, definidas como algoritmos criados com

o objetivo de quantificar tal estrutura e características (FRAZIER, 2019). Os detalhes sobre as métricas de paisagem utilizadas no trabalho são apresentados na Tabela a seguir:

Tabela 2 - Descrição das métricas de paisagem utilizadas no trabalho.

Métrica	Nome	Unidade	Descrição
PLAND	<i>Percentage of Landscape</i>	%	Soma das áreas de todas as manchas (m ²) da classe correspondente dividida pela área total da paisagem (m ²) multiplicada por 100.
TCA	<i>Total Core Area</i>	m ²	Soma das áreas centrais de cada mancha (m ²) da classe correspondente.
MPA	<i>Mean Patch Area</i>	m ²	Soma das áreas (m ²) de todas as manchas da classe correspondente dividido pelo número de manchas da classe.
ED	<i>Edge Density</i>	m/ha	Soma dos comprimentos (m) de todos os segmentos de borda envolvendo a classe correspondente, dividido pela área total da paisagem (m ²), multiplicado por 10000 para converter em hectares.
NP	<i>Number of Patches</i>	–	Número total de manchas da classe correspondente.

Fonte: Fragstats.

As métricas foram extraídas do mapa binário de floresta/não floresta e agregadas para a grade de 35km utilizando o pacote Landscape Metrics, disponível no Rstudio (<https://cran.r-project.org/web/packages/landscapemetrics/index.html>).

Para avaliar a relação entre as variáveis de fragmentação e a ocorrência de queimadas utilizou-se o modelo de regressão espacial local, *Geographically Weighted Regression (GWR)*, um modelo multivariado não paramétrico que pode indicar onde a não estacionariedade ocorre no espaço (YU et al., 2009). A primeira etapa em uma análise espacial de dados geográficos é a análise exploratória das variáveis. Neste caso, aplicou-se uma análise de autocorrelação dos dados, de modo a identificar a estrutura de correlação espacial que melhor descreve os dados. A ideia básica é estimar a magnitude da autocorrelação espacial entre as áreas. Tal análise parte do pressuposto da existência dos efeitos de proximidade, onde segundo a 1^o Lei da Geografia (Lei de Tobler) “coisas mais próximas são mais parecidas do que coisas mais distantes” e, que eventos próximos no espaço apresentam autocorrelação espacial. Caso haja ausência de qualquer padrão ou estrutura espacial entre os dados indica-se aleatoriedade espacial. A autocorrelação espacial pode ser positiva ou negativa, onde a primeira refere-se ao pressuposto de que feições similares em localização também são similares em atributos, ao passo que a segunda indica uma oposição à lei de Tobler. Com o objetivo de estimar a variabilidade espacial dos dados, calculou-se a Matriz de Proximidade Espacial, também chamada de Matriz de Vizinhaça. Dado um conjunto de n áreas $\{A_1, \dots, A_n\}$, construímos a matriz de pesos $W(1)$ ($n \times n$), onde cada um dos elementos w_{ij} representa uma medida de proximidade entre A_i e A_j . A medida de proximidade, também chamada de critério de vizinhaça, pode ser obtida a partir de dois critérios: contiguidade ou distância (CARVALHO et al., 2004). Neste trabalho optou-se por utilizar o critério de contiguidade, onde

$$w_{ij} = 1, \text{ se as regiões } i \text{ e } j \text{ são contíguas, ou seja, vizinhas.}$$

$$w_{ij} = 0, \text{ caso contrário.}$$

Utilizou-se no trabalho em questão a Matriz de Proximidade normalizada, para que a soma dos pesos de cada linha seja igual a 1. Isto simplifica muito vários cálculos de índices de autocorrelação espacial. Em sequência, calculou-se o índice global e local de Moran. O índice global de Moran I é a expressão da autocorrelação considerando apenas o primeiro vizinho e é calculado considerando a seguinte fórmula:

$$I = \frac{\sum_{i=1}^n \sum_{j=1}^n w_{ij} (z_i - \bar{z})(z_j - \bar{z})}{\sum_{i=1}^n (z_i - \bar{z})^2}$$

onde,

n é o número de áreas

z_i é o valor do atributo considerado na área i

\bar{z} é o valor médio do atributo na região de estudo

w_{ij} são os elementos da matriz normalizada de proximidade espacial

O índice de Moran varia de -1 a +1, cuja hipótese nula é de independência espacial; neste caso, seu valor seria zero. Assim, valores positivos (entre 0 e +1) indicam para autocorrelação direta, enquanto os valores negativos (entre 0 e -1) expressam autocorrelação inversa. Os indicadores globais fornecem, como já exposto, um único valor como medida de associação espacial para todo o conjunto de dados. Entretanto, quando lida-se com um grande número de áreas é possível que ocorram diferentes regimes de associação espacial. Para isso, calculou-se também os índices de autocorrelação locais de Moran, os quais produzem um valor de Moran específico para cada área, permitindo, deste modo, a identificação dos agrupamentos. A partir deste processo foi gerado como resultado o LISA MAP, que expõe espacialmente os indicadores locais significativos (p -valor < 0.05) e não significativos (p -valor > 0.05), através da decomposição do índice global (CARVALHO et al., 2004).

Posteriormente, iniciou-se a etapa de aplicação do modelo de regressão espacial. A regressão espacial pode ser global ou local, onde a primeira refere-se à estatísticas que dizem respeito à região como um todo (globais) e, não mapeáveis, ao passo que a segunda refere-se ao modelo, cujo parâmetros variam continuamente no espaço, ou seja, são caracterizadas por desagregações locais das estatísticas globais, procurando por exceções ou “hot-spots” locais. A GWR, modelo utilizado no trabalho, ajusta um modelo de regressão a cada ponto observado (YU et al., 2009), ponderando todas as demais observações como função de distância a este ponto, sendo que dois parâmetros são importantes:

Função de kernel – função sobre cada ponto usada para ponderar os pontos vizinhos em razão da distância. Assim sendo, os pontos mais próximos do ponto central têm maior peso.

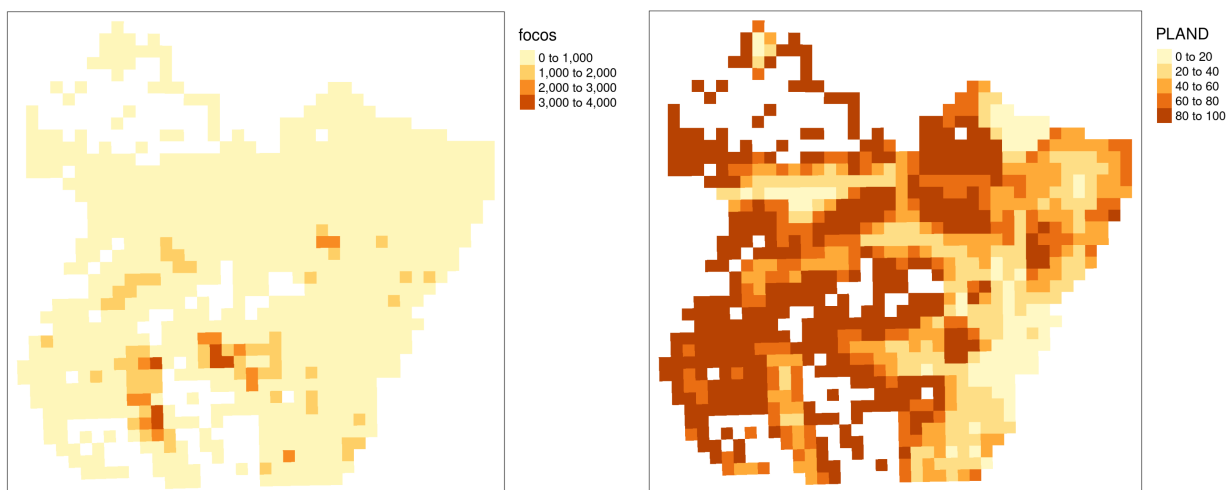
Largura de banda – pode ser fixa ou adaptativa à densidade dos dados.

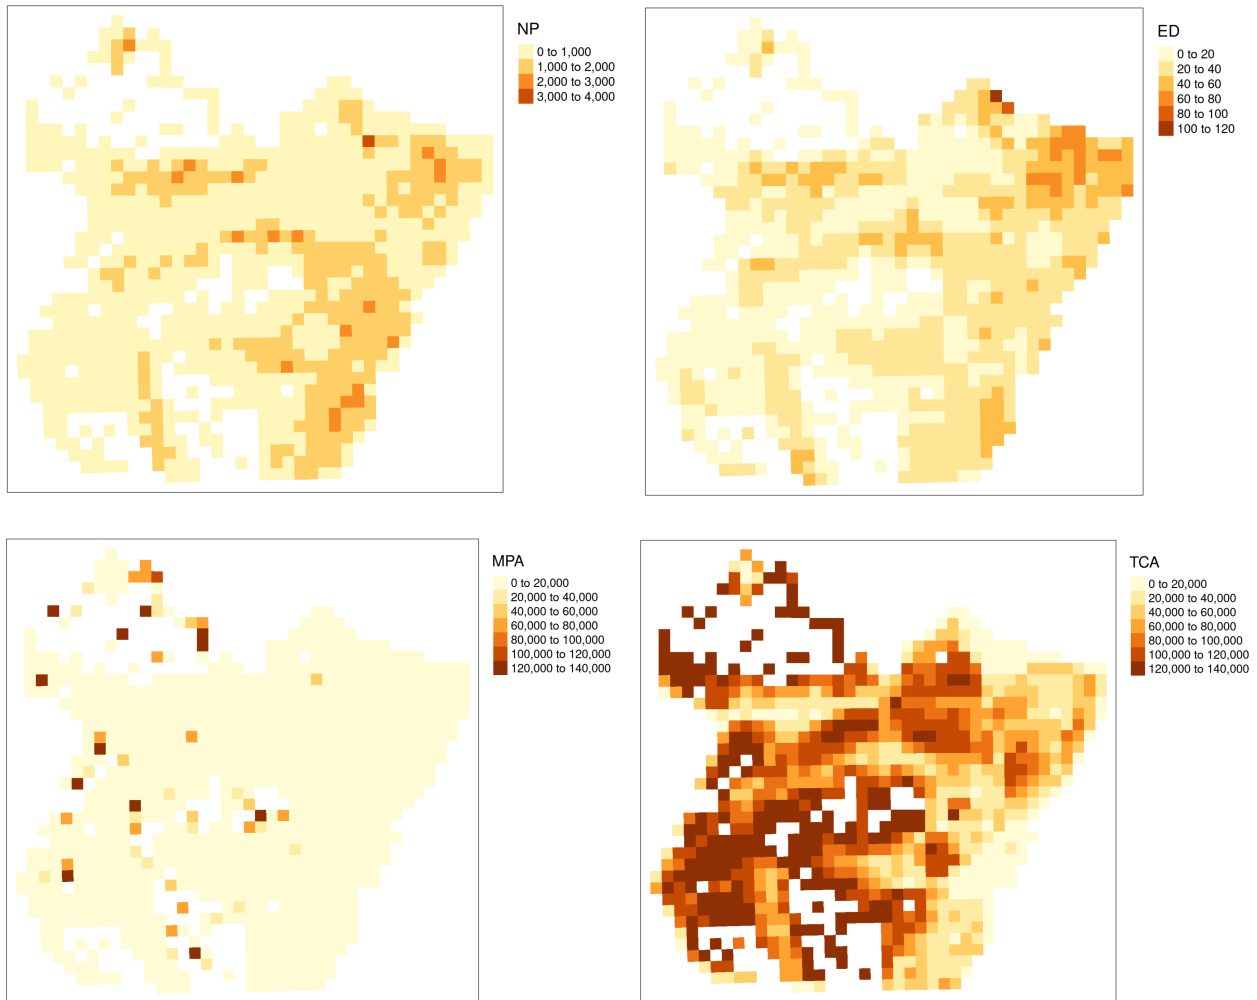
Por fim, foi calculado a Raiz do Erro Médio Quadrático (Root Mean Square Error - RMSE), onde o menor valor indica o melhor modelo e, foi usada para comparar entre o modelo com uma largura de banda fixa e o modelo com uma largura de banda adaptativa.

3. RESULTADOS E DISCUSSÃO

Com base na extração das métricas (PLAND, NP, ED, MPA e TCA) é possível identificar o padrão espacial da estrutura da paisagem (Figura 2), bem como analisar o grau de fragmentação florestal da área de estudo.

Figura 2 - Mapas com a espacialização das variáveis de estudo (focos de calor e métricas da paisagem).





Fonte: os autores.

Observa-se que as regiões com a menor porcentagem florestal localizam-se majoritariamente na porção leste do estado do Pará, concomitante às maiores taxas de densidade de borda, localizadas na região nordeste e, também às altas taxas de número de manchas (entre 1000 - 2000 manchas em cada célula). O número de manchas é uma das métricas principais para quantificar paisagens fragmentadas, onde uma unidade de paisagem com elevados números de manchas representa áreas mais fragmentadas e, conseqüentemente, mais desmatadas. Tal fato pode ser associado às elevadas taxas de desmatamento nessas regiões do estado, a qual leva a conversão da floresta em agricultura ou pastagem, desmatando e aumentando o grau de fragmentação da área.

No entanto, a região com a maior porcentagem florestal localiza-se majoritariamente na porção oeste do estado, com muitas células com porcentagem de floresta acima de 80%, evidenciando um alto grau de preservação ambiental dessas regiões. Além disso, as células que apresentam valores de Área Core altos são concomitantes com as células que apresentam PLAND mais alto. A área core representa a área interior das manchas após a eliminação das bordas, ou seja, refere-se a área não afetada pela borda. Por fim, as células que apresentam o maior valor médio de tamanho de mancha localizam-se também concentradas na região oeste.

A partir da aplicação do teste de autocorrelação espacial de Moran obteve-se um índice global de 0.474 ($p < 0.05$) para os dados de focos de calor (variável dependente da análise), evidenciando uma autocorrelação positiva e direta dos dados. Os mapas a seguir mostram a espacialização dos resultados obtidos com o cálculo dos índices locais de Moran, onde:

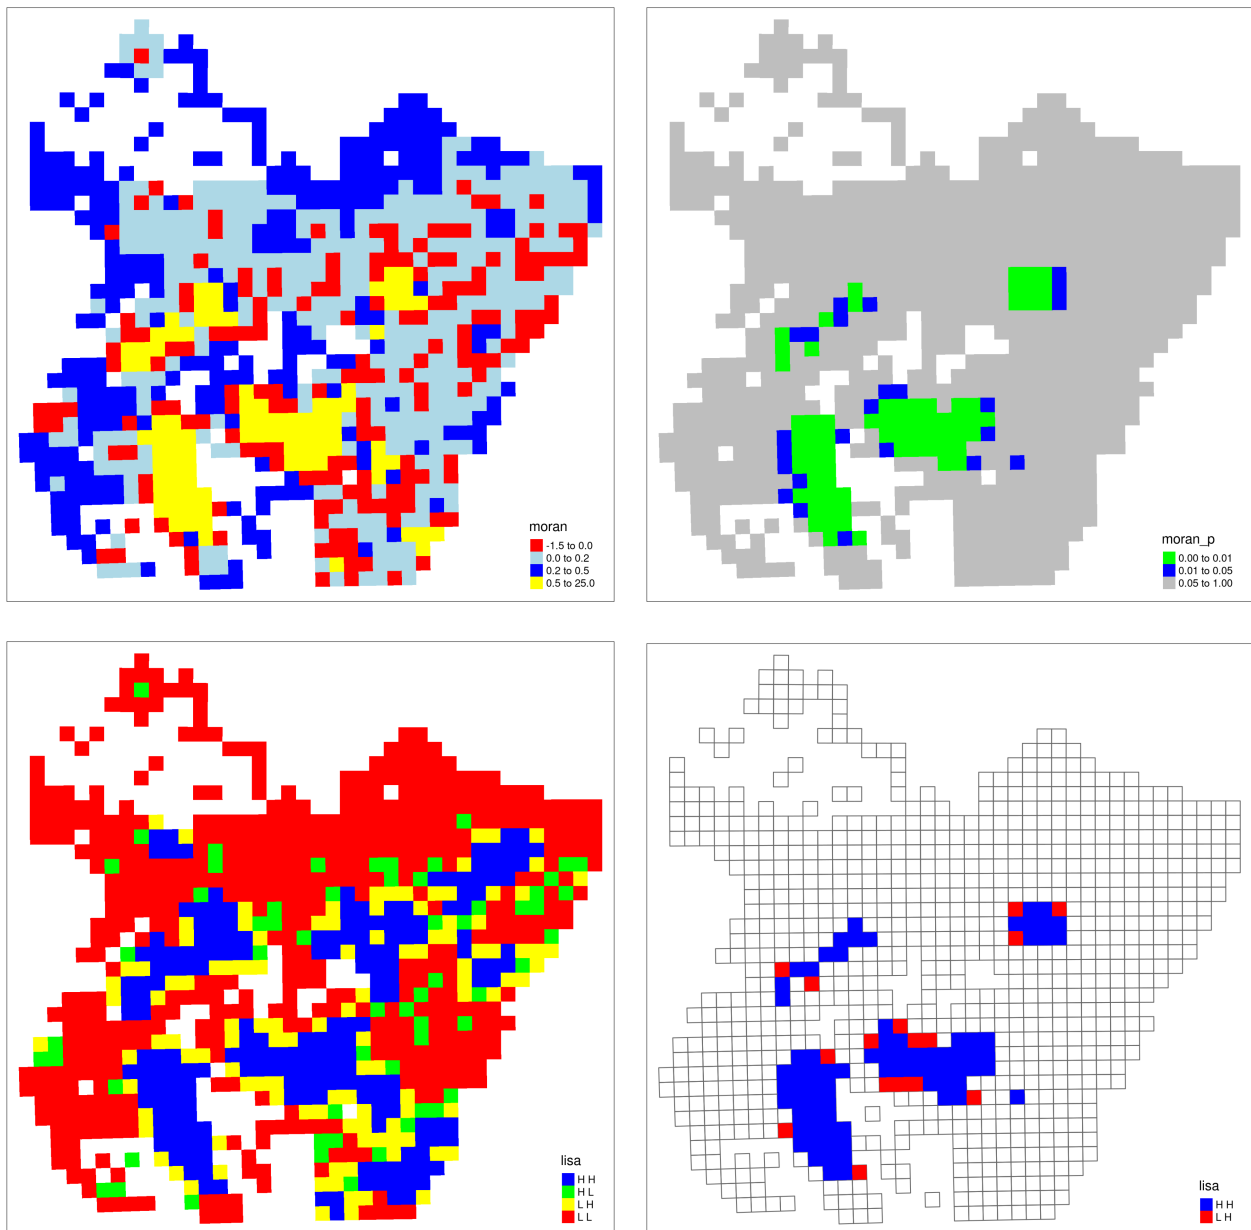
Mapa 1: índice local de Moran para cada uma das áreas.

Mapa 2: nível de significância (p-valor) de cada uma das áreas.

Mapa 3: espacialização do diagrama de espalhamento de Moran, dividido em low-low (LL), high-high (HH), high-low (HL) e low-high (LH).

Mapa 4: LISA Map descartando as áreas que obtiveram índice local não significante.

Figura 3 - Espacialização dos resultados obtidos com o cálculo dos índices locais de Moran. Mapa 1 (superior à direita). Mapa 2 (superior à esquerda). Mapa 3 (inferior à direita). Mapa 4 (inferior à esquerda).



Fonte: os autores.

Observa-se que as regiões que apresentaram os maiores valores de índice de autocorrelação positiva e direta são também aquelas que apresentaram p-valores significativos (< 0.05) e, também pontos de associação espacial High-High (HH). Um ponto de associação HH indica que nessas áreas os valores de focos de calor são altos e, suas regiões vizinhas também apresentam valores de focos de calor altos, indicando nestas porções pontos quentes de ocorrência de queimadas. Tais pontos quentes também podem ser confirmados ao analisar o mapa com a espacialização dos focos de calor (Figura 2), o qual também apresenta seus maiores valores nas mesmas células, localizadas na região centro-sul do estado. No entanto, os valores de índice de autocorrelação negativa são também aqueles que apresentaram p-valores não significantes, sendo descartados do LISA Map.

Os resultados obtidos com a regressão espacial local, *Geographically Weighted Regression (GWR)*, podem ser visualizados na Tabela a seguir:

Tabela 3 - Resultados obtidos com a aplicação do modelo de regressão espacial local, GWR.

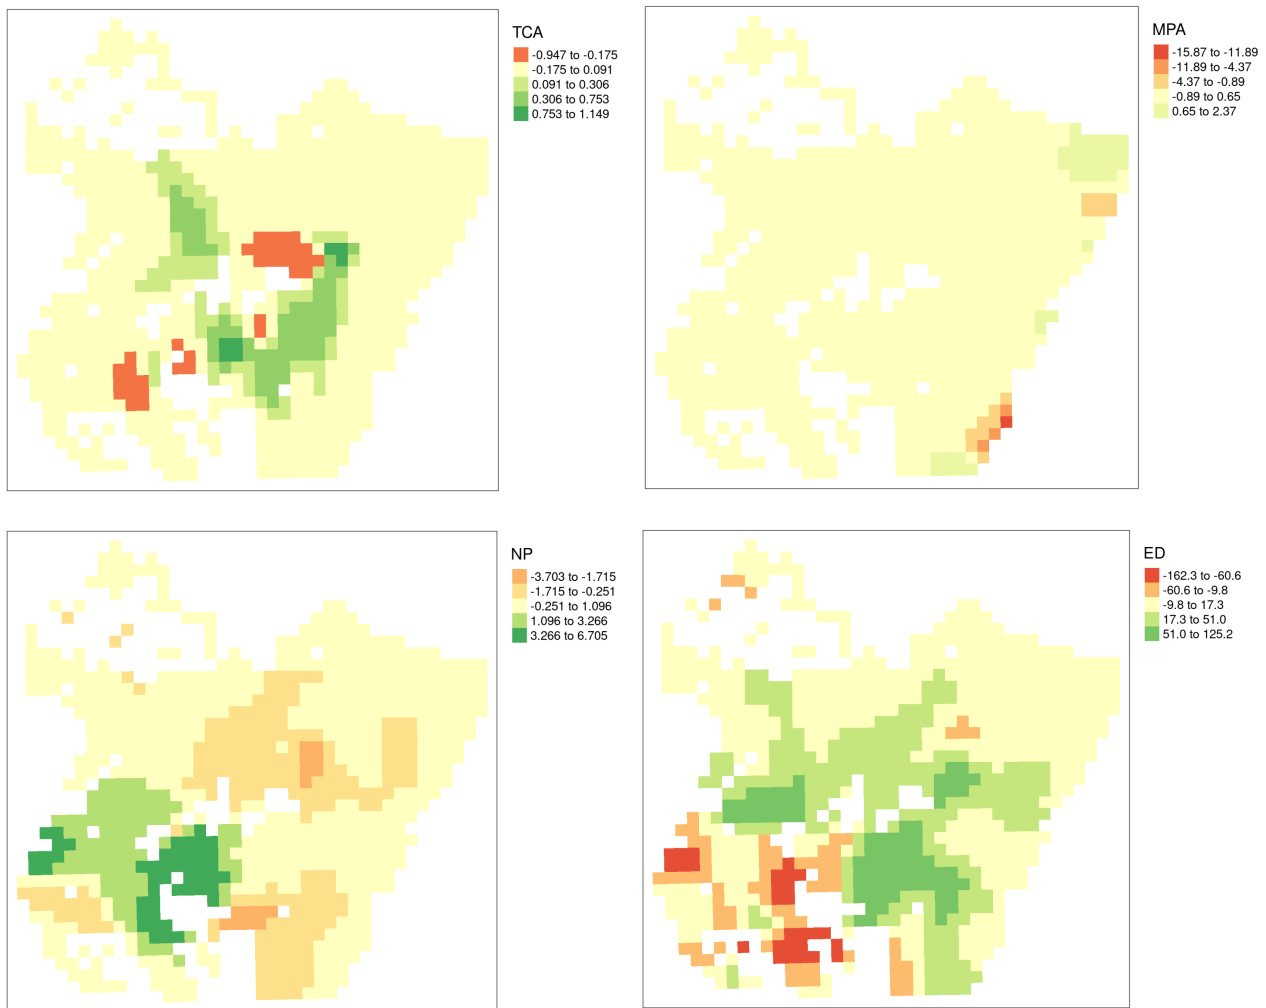
GWR	Valor do raio	RMSE
Raio fixo	47109.78	210.9908
Raio adaptativo	0.006911744	223.2904


Fonte: os autores.

É possível observar que o modelo que apresentou o menor erro foi utilizando uma largura de banda fixa. Deste modo, variar o raio ao longo das regressões locais realizadas em cada uma das células não interfere na obtenção de um melhor modelo. Optou-se então por seguir com a realização de uma regressão espacial local GWR com o uso de uma largura de banda fixa.

Outro resultado interessante de se analisar é o mapeamento feito com base nos coeficientes de predição de cada variável explicativa (PLAND, NP, ED, MPA e TCA), onde quanto maior é o valor, maior é a influência da variável explicativa em responder a variável resposta. É possível mapear também os valores dos R² locais, analisando, então, em quais regiões o modelo consegue explicar bem e onde que o modelo é falho (Figura 4). Neste caso, observa-se que os maiores valores de R² localizam-se majoritariamente na porção oeste do estado e, em algumas células da região nordeste, indicando nestas regiões a maior capacidade do modelo em predizer o comportamento da variável resposta.

Figura 4 - Espacialização dos resultados obtidos com a aplicação do modelo de regressão espacial local, GWR.





Fonte: os autores.

Com base na análise da espacialização dos coeficientes de predição (PLAND, TCA, MPA, NP e ED) é possível extrair alguns comportamentos da variável resposta de estudo (focos de calor). Com relação à variável explicativa PLAND observa-se que há alguns setores (em cor verde no mapa) onde a porcentagem de floresta contribui positivamente para explicação da ocorrência de queimadas (variável resposta), concomitante com os mesmos setores que apresentam a maior ocorrência de focos de calor no ano de 2020. Deste modo, evidencia-se que caso haja aumento na porcentagem de floresta também teremos um aumento nos focos de calor. A partir dessa análise algumas perguntas e hipóteses são colocadas em questão: Há então uma pressão antrópica para dentro das áreas de floresta ombrófila densa? Temos um enfraquecimento das leis ambientais e falta de proteção das áreas protegidas fazendo com que o fogo avance para dentro dessas áreas?

Entretanto, com relação à métrica TCA observa-se o processo inverso quando comparado com a variável PLAND, ou seja, em regiões que PLAND contribui positivamente para explicação da variável resposta, TCA contribui negativamente e, vice-versa. Além disso, com base na análise dos mapas evidencia-se que a variável MPA explica pouco a variável resposta, podendo até ser descartada da análise.

Com relação à métrica NP, os setores onde a variável número de manchas contribui positivamente para explicação da variável resposta localizam-se na porção sudoeste do estado, ou seja, nessas áreas observa-se que à medida que temos o aumento do número de manchas temos também uma tendência em aumento na ocorrência de focos de calor. Nessas porções do território encontram-se as áreas de tensão ecológica e, também, algumas áreas protegidas do tipo uso sustentável ou até mesmo porções de áreas não protegidas. Porém, ainda é uma área com alta porcentagem de floresta. Seria, então, uma área com tendência ao avanço do fogo e do desmatamento? Seria uma região suscetível à ocorrência e intensificação dos distúrbios antrópicos?

Por fim, ao analisar o mapa de espacialização da variável explicativa ED, observa-se um comportamento inverso da densidade de borda quando comparado com a variável NP, ou seja, na porção sudoeste do estado, onde NP contribui positivamente para explicação da variável resposta, ED contribui negativamente e, vice-versa. Novas hipóteses e perguntas são levantadas: Este comportamento ocorre porque a área ainda apresenta altas porcentagens de floresta (nível alto de preservação), indicando baixa fragmentação da paisagem e, assim, pouca presença de bordas? Seria uma possível região de preocupação no futuro?

De modo geral, as análises realizadas no trabalho indicam que paisagens mais fragmentadas, com manchas pequenas e alta densidade de borda, tendem a ser mais vulneráveis aos distúrbios antrópicos (como é o caso do fogo), do que paisagens florestais intactas e contínuas (SILVA JÚNIOR et al., 2018).

4. CONCLUSÕES

A aplicação do modelo de regressão espacial local, *Geographically Weighted Regression* (GWR), se mostrou de suma importância para o entendimento de quais métricas da paisagem (PLAND, NP, ED, MPA e TCA) influenciam mais no comportamento da variável resposta de análise (focos de calor) e, também de modo a abrir perguntas, questionamentos e hipóteses dos fatores e processos que levam a intensificação da ocorrência de queimadas e incêndios florestais no estado do Pará para o ano de 2020. Dentre os questionamentos levantados destacam-se: [1] Há realmente uma pressão antrópica dentro das áreas de floresta ombrófila densa? [2] Na atualidade, o enfraquecimento das leis ambientais e a falta de proteção e gestão das áreas protegidas estão fazendo com que o fogo avance para dentro de tais áreas? [3] A região sudoeste do estado do Pará será uma região suscetível à ocorrência e intensificação do fogo e do desmatamento no futuro? Tais perguntas serão alvo de estudo e entendimento em trabalhos futuros.

Entretanto, tal método também apresentou limitações, pois o GWR, assim como outros modelos de regressão espacial, pressupõe a existência de alguns requisitos, tais como: linearidade entre as variáveis e normalidade dos resíduos. Em trabalhos futuros com o intuito de melhorar a eficiência e a capacidade do modelo em prever o comportamento da variável resposta seria importante aplicar transformações matemáticas de modo a linearizar e normalizar os dados, como por exemplo, transformação logarítmica ou transformação Box-Cox. Outro ponto importante também, diz respeito à necessidade de em trabalhos futuros analisar os impactos dos efeitos de 2º ordem de modo a evidenciar para o pesquisador os efeitos da não estacionaridade dos dados.

REFERÊNCIAS BIBLIOGRÁFICAS

ALENCAR, A. A.; BRANDO, P. M.; ASNER, G. P.; PUTZ, F. E. Landscape fragmentation, severe drought, and the new Amazon forest fire regime. **Ecological Applications: Ecological Society of America**, v. 25, n. 6, p. 1493-1505, 2015.

ANDERSON, L.O.; et al. Detecção de cicatrizes de áreas queimadas baseada no modelo linear de mistura espectral e imagens índice de vegetação utilizando dados multitemporais do sensor MODIS/TERRA no estado do Mato Grosso, Amazônia brasileira. **Acta Amazonica**, 35, 445–456. 2005.

ANDERSON, L. O. et al. Counting the costs of the 2005 Amazon drought: A preliminary assessment, in Ecosystem Services for Poverty Alleviation in Amazonia. In: MEIR, P. (Ed.). **Ecosystem Services for Poverty Alleviation in Amazonia**. Edinburgh. p. 96–108. 2011.

ANDERSON, L. O.; BURTON, C.; DOS REIS, J. B. C.; PESSÔA, A. C. M.; BETT, P.; CARVALHO, N. S.; SELAYA, G.; JONES, C.; RIVERA-LOMBARDI, R.; ARAGÃO, L. E. O. C.; SILVA JUNIOR, C.; XAUD, H.; WILTSHIRE, A.; FERREIRA, J.; ARMENTERAS, D.; BILBAO, B. **Fire probability in South American Protected Areas Brazilian Settlements and Rural Properties in the Brazilian Amazon: December 2020 to February 2021**. 32p. São José dos Campos, 2020. SEI/Cemaden processo 01250.029118/2018- 78/6265429.

ARAGÃO, L. E. O.; et al. Interactions between rainfall, deforestation and fires during recent years in the Brazilian Amazonia. **Philosophical Transactions of the Royal Society of London**, v. 363, p. 1779–1785, 2008.

ARAGÃO, L. E. O. C.; et al. 21st Century drought-related fires counteract the decline of Amazon deforestation carbon emissions. **Nature Communications**, vol. 9, n. 1, p. 536, 2018.

ARMENTERAS, D.; GONZÁLEZ, T. M; RETANA, J. Forest fragmentation and edge influence on fire occurrence and intensity under different management types in Amazon forests. **Biological Conservation**, v. 159, p. 73-79, 2013.

BARLOW, J. et al. The critical importance of considering fire in REDD+ programs. **Biological Conservation**, v. 154, p. 1–8, 2012.

BENNET, A. F.; SAUNDERS, D. **Habitat Fragmentation and Landscape Change**. In: Conservation Biology for All. Publisher: Oxford University, p. 881-3706, 2011.

BRASIL. Ministério do Meio Ambiente. **Planaveg: Plano Nacional de Recuperação da Vegetação Nativa**. Ministério do Meio Ambiente, Ministério da Agricultura, Pecuária e Abastecimento, Ministério da Educação. Brasília, DF: MMA, 2017. 73 p.

BURTON, C.; BETTS, R. A.; JONES, C. D.; FELDPAUSCH, T. R.; CARDOSO, M.; ANDERSON, L. O. El Niño Driven Changes in Global Fire 2015/16. **Frontiers in Earth Science**, v. 8, n. 199, p. 1-12, June 2020.

CAMPANHARO, W. et al. Translating Fire Impacts in Southwestern Amazonia into Economic Costs. **Remote Sensing**, v. 11, n. 7, p. 764, 2019.

CARVALHO, M. S.; CÂMARA, G.; CRUZ, O. G.; CORREA, V. **Análise de Dados de Área**. In: DRUCK, S.; CARVALHO, M. S.; CÂMARA, G.; MONTEIRO, A. V. M. *Análise Espacial de Dados Geográficos*. Brasília, EMBRAPA, 2004 (ISBN: 85-7383-260-6).

CHUVIECO, E. et al. Integration of ecological and socio-economic factors to assess global vulnerability to wildfire. **Global Ecology and Biogeography**, v. 23, n. 2, p. 245–258, 2014.

DAVIDSON, E., et al. The Amazon basin in transition. **Nature**, v. 481, p. 321–328. 2012.

FEARNSIDE, P. M. Deforestation in Brazilian Amazonia: History, Rates, and Consequences. **Conservation Biology**, v. 19, n. 3, p. 680–688, 2005.

FORMAN, T. T.; GODRON, M. **Landscape ecology**. John Wiley and Sons, United States, 1986.

FRAZIER, A. **Landscape Metrics**. The Geographic Information Science & Technology Body of Knowledge. John P. Wilson (Ed.), 2019.

GIGLIO, L.; et al. The Collection 6 MODIS burned area mapping algorithm and product. **Remote Sensing of Environment**, v. 217, p. 72-85, 2018.

JUÁREZ-OROZCO, S. M.; SIEBE, C.; FERNÁNDEZ Y FERNÁNDEZ, D. Causes and Effects of Forest Fires in Tropical Rainforests: A Bibliometric Approach. **Tropical Conservation Science**, v. 10, 2017.

METZGER, J. P. O que é Ecologia de Paisagens? **Biota Neotropica**, v. 1, n. 1, 2001.

METZGER, J. P. Como restaurar a conectividade de paisagens fragmentadas? In.: KAGEYAMA, P. Y.; OLIVEIRA, R. E.; MORAES, L. F. D.; ENGEL, V. L.; GANDARA, F. B. **Restauração ecológica de ecossistemas naturais**. Botucatu: FEPAF, 2003. p.51 –76.

MORTON, D. C., et al. Agricultural intensification increases deforestation fire activity in Amazonia. **Global Change Biology**, v.14. 2008.

MÜLLER, C. **Brazil and the Amazon rainforest: deforestation, biodiversity and cooperation with the EU and international forums.** European parliament. 2020. Disponível em: [https://www.europarl.europa.eu/thinktank/en/document.html?reference=IPOL_IDA\(2020\)648792](https://www.europarl.europa.eu/thinktank/en/document.html?reference=IPOL_IDA(2020)648792). Acessado em: 02 dez. 2021.

MYERS, N., et al. Biodiversity hotspots for conservation priorities. **Nature**, v. 403, p. 853-858, 2000.

OOM, D.; PEREIRA, J. M. C. Exploratory spatial data analysis of global MODIS active fire data. **International Journal of Applied Earth Observation and Geoinformation**, v. 21, p. 326-340, 2013.

PIVELLO, V. R.; et al. Understanding Brazil's catastrophic fires: Causes, consequences and policy needed to prevent future tragedies. **Perspectives in ecology and conservation**, v. 19, p. 233-255, 2021.

PRIMACK, R. B.; RODRIGUES, E. **Biologia da Conservação.** Londrina: Editora Planta. 2001.

RIBEIRO, R. M.; AMARAL, S.; MONTEIRO, A. M. V.; DAL'ASTA, A. P. Os processos de urbanização e conversão florestal na Amazônia paraense – um estudo multiescalar. **Revista Brasileira de Estudos de População**, v. 35, n. 3. 2018.

SANTOS, A. M. d., et al. Dynamics of active fire data and their relationship with fires in the areas of regularized indigenous lands in the Southern Amazon. **Remote Sensing Applications: Society and Environment**. v. 23, 2021.

SHIMABUKURO, et al. Mapping Burned Areas of Mato Grosso State Brazilian Amazon Using Multisensor Datasets. **Remote Sensing**, v. 12, p. 3827, 2020.

SILVA JUNIOR, C. H. L.; ARAGÃO, L. E. O. C.; FONSECA, M. G.; ALMEIDA, C. T.; VEDOVATO, L. B.; ANDERSON, L. O. Deforestation-Induced Fragmentation Increase Forest Fire Occurrence in Central Brazilian Amazonia. **Forests**, v. 9, n. 305, p. 1-16, 2018.

VEENENDAAL, E. M. et al. Structural, physiognomic and above-ground biomass variation in savanna–forest transition zones on three continents – how different are co-occurring savanna and forest formations?. **Biogeosciences**, v. 12, n. 10, p. 2927–2951, 2015.

YU, D.; PETERSON, N. A.; REID, R. J. 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, n. 3, p. 329–346, 2009.