



# Point Process Analysis applied to fire outbreaks in São Paulo

Vinicius Crispim Tavares Monteiro <sup>1</sup> \*   
Manoel Alves de Oliveira <sup>2</sup>   
Ricardo Alves de Olinda <sup>3</sup>   
Lucas Cardoso Pereira <sup>4</sup> 

<sup>1 2 3 4 5</sup> Departamento de Estatística, State University of Paraíba, Campina Grande, Brazil  
Emails: <sup>1</sup> [vinicius.monteiro@aluno.uepb.edu.br](mailto:vinicius.monteiro@aluno.uepb.edu.br); <sup>2</sup> [manoel.alves.oliveira@aluno.uepb.edu.br](mailto:manoel.alves.oliveira@aluno.uepb.edu.br);  
<sup>3</sup> [prof\\_ricardo@servidor.uepb.edu.br](mailto:prof_ricardo@servidor.uepb.edu.br); <sup>4</sup> [lucascardoso@servidor.uepb.edu.br](mailto:lucascardoso@servidor.uepb.edu.br)  
\* corresponding author

**How to cite this paper:** Monteiro, V. C. T., de Oliveira, M. A., de Olinda, R. A. Pereira, L. C. (2024). Point Process Analysis applied to fire outbreaks in São Paulo. *Socioeconomic Analytics*, 2(1), 164-174.  
<https://doi.org/10.51359/2965-4661.2024.265082>

## RESEARCH ARTICLE

**Socioeconomic Analytics**  
<https://periodicos.ufpe.br/revistas/SECAN/>  
ISSN Online: 2965-4661

**Submitted on:** 25.11.2024.  
**Accepted on:** 15.12.2024.  
**Published on:** 27.12.2024.

Copyright © 2024 by author(s).

This work is licensed under the Creative Commons Attribution International License CC BY-NC-ND 4.0  
<http://creativecommons.org/licenses/by-nc-nd/4.0/deed.en>



## Abstract

This study applied spatial analysis techniques to point processes to investigate the distribution of fire outbreaks in the state of São Paulo during the months of June to September 2024. Using data from the Burning Program of the National Institute for Space Research (INPE), descriptive and inferential analyses were performed, including Ripley's K Function and the Kolmogorov-Smirnov Test, with the aim of testing the hypothesis of Complete Spatial Randomness (CSR). The results indicated a pattern of spatial clustering in short distances, rejecting the hypothesis of randomness. Predictive models based on Poisson processes were adjusted, highlighting the most vulnerable areas, especially in the Atlantic Forest and Cerrado biomes. This work reinforces the importance of spatial statistics as an essential tool for identifying patterns and planning mitigation strategies, contributing to environmental preservation and combating fire outbreaks.

## Keywords

Point Process Analysis, Spatial Statistics, Fires, Hypothesis Tests, São Paulo.

## 1. Introdução

Os focos de incêndio, são ocorrências que possuem impacto significativo nos ecossistemas, na economia e na saúde humana. Eles podem ser causados devido a fatores naturais, como raios em florestas secas, mas frequentemente são resultado de atividades humanas, incluindo a agricultura, a pecuária e o desmatamento. Esses incêndios prejudicam o ciclo das chuvas e contribuem para mudanças climáticas a longo prazo, afetando a temperatura e a precipitação (IBAMA, 2024).

Medidas de monitoramento e controle de incêndios são fundamentais para a preservação ambiental. Órgãos como o Instituto Nacional de Pesquisas Espaciais (INPE), no Brasil, utilizam satélites para detectar focos de calor e incêndios em tempo real, fornecendo dados importantes para a atuação de brigadas e a aplicação de políticas ambientais (AMBIENTE, 2024).

A estatística espacial é uma área da estatística dedicada ao estudo de dados que possuem uma localização geográfica associada. Esse campo se aplica em várias áreas, como ecologia, epidemiologia, geologia, planejamento urbano, entre outras. A estatística espacial trabalha com a análise de padrões, distribuição e dependência espacial em dados, sendo fundamental para entender fenômenos que ocorrem em um espaço contínuo ou discreto (CRESSIE, 1993).

Dentro da estatística espacial existem os processos pontuais, que são utilizados para modelar a distribuição de pontos em uma determinada região do espaço. Esses eventos podem representar, por exemplo, a localização de focos de incêndio, a ocorrência de uma doença em indivíduos, ou a distribuição de espécies em um habitat. Um processo pontual é uma coleção de eventos que ocorrem em uma área ou volume e pode ser descrito por sua intensidade e suas propriedades de dependência espacial (DIGGLE, 2013).

Ao analisar processos pontuais, algumas hipóteses são formuladas para descrever a distribuição dos pontos no espaço. A hipótese de Completa Aleatoriedade Espacial (CSR) supõe que os eventos são distribuídos aleatoriamente em um espaço, de forma que qualquer ponto tem a mesma probabilidade de ocorrência em qualquer localização da área de estudo. Um exemplo de processo que aceita essa hipótese é o processo de Poisson homogêneo. A CSR é frequentemente utilizada como um ponto de comparação para determinar se existe uma estrutura subjacente nos dados (BADDELEY, RUBAK, & TURNER, 2015).

Para testar a hipótese de Completa Aleatoriedade Espacial (CSR) em processos pontuais, pode-se utilizar diversas funções. Essas funções avaliam se os pontos estão distribuídos de maneira aleatória no espaço ou se existe algum tipo de estrutura subjacente, como aglomeração ou dispersão dos dados. Algumas das funções mais utilizadas são: Função K de Ripley; Função G de Vizinho Mais Próximo; Função F de Espaço Vazio (BADDELEY, RUBAK, & TURNER, 2015).

Com base nisso, o objetivo desse trabalho é realizar uma análise espacial em processos pontuais com base no comportamento dos focos de incêndio ocorridos no estado de São Paulo entre os meses de junho e setembro do ano de 2024. Como objetivos específicos temos: Testar a hipótese de Completa Aleatoriedade Espacial (CSR) e investigar se os dados correspondem a um processo de Poisson homogêneo.; verificar se a distribuição dos focos de

incêndio no estado segue um padrão aleatório, sistemático ou de agrupamento; ajustar um modelo para a predição de focos de incêndios no estado; averiguar quais as regiões do estado mais afetadas pelos incêndios durante o período de estudo

## 2. Materiais e Métodos

O banco de dados sob estudo provém do Programa Queimadas do Instituto Nacional de Pesquisas Espaciais (INPE), uma página que oferece dados em tempo real sobre focos de incêndio no Brasil (INPE, 2024). É composto por 12 variáveis e 4819 observações, e corresponde aos incêndios ocorridos no estado de São Paulo entre os meses de junho e setembro de 2024, foi solicitado no site em formato csv e recebido por e-mail em uma pasta compactada. Na Tabela 1 estão expostas as variáveis contidas no banco de dados e suas respectivas classificações.

Tabela 1: Tabela das variáveis e suas classificações.

Variáveis	Classificação
DataHora	Quantitativa contínua
Satelite	Qualitativa nominal
Pais	Qualitativa nominal
Estado	Qualitativa nominal
Municipio	Qualitativa nominal
Bioma	Qualitativa nominal
DiaSemChuva	Quantitativa discreta
Precipitação	Quantitativa contínua
RiscoFogo	Quantitativa contínua
Latitude	Quantitativa contínua
Longitude	Quantitativa contínua
FRP	Quantitativa contínua

Fonte: Elaborado pelo autor, (2024).

Para executar a análise, serão aplicadas algumas técnicas de estatística descritiva com o intuito de observar o comportamento dos focos de incêndio no estado de São Paulo. Em seguida serão utilizados métodos da estatística espacial para avaliar e compreender por meio de mapas, as ocorrências de incêndio no estado, bem como averiguar possíveis indícios de agrupamento na distribuição dos focos. Além disso, serão aplicados testes não paramétricos para confirmar a existência de algum padrão na distribuição dos incêndios, assim como um ajuste de modelo para a predição de ocorrências de incêndio durante o período de estudo. Vale ressaltar que toda a análise foi realizada através do software gratuito R Studio, a listagem dos comandos está disponível nos anexos.

### 2.1 Estimador de Intensidade de Kernel

O Estimador de Intensidade de Kernel é uma ferramenta essencial na estatística espacial para estimar a intensidade de pontos ao longo de uma área, ou seja, para medir a "densidade" de eventos em diferentes partes do espaço. É uma técnica de suavização que calcula a densidade de pontos ao redor de cada localização, fornecendo uma estimativa contínua da intensidade do processo em qualquer ponto do espaço. Esse método envolve a escolha de uma função

kernel e uma largura de banda que determina o raio de influência de cada ponto sobre a área ao redor (DIGGLE, 2013).

A partir dos conceitos apresentados, suponha que  $u_1, \dots, u_n$  são localizações de  $n$  eventos observados em uma região  $A$  e que  $u$  represente uma localização genérica cujo valor queremos estimar. O estimador de intensidade é computado a partir dos  $m$  eventos  $\{u_i, \dots, u_{i+m-1}\}$  contidos num raio de tamanho  $\tau$  em torno de  $u$  e da distância  $d$  entre a posição e a  $i$ -ésima amostra, a partir de funções cuja forma geral é (CÂMARA & CARVALHO, 2004):

$$\hat{\lambda}_\tau(u) = \frac{1}{\tau^2} \sum_{i=1}^n k\left(\frac{d(u_i, u)}{\tau}\right), d(u_i, u) \leq \tau. \quad (1)$$

Este estimador é chamado *kernel estimator* e seus parâmetros básicos são: (a) um raio de influência ( $\tau \geq 0$ ) que define a vizinhança do ponto a ser interpolado e controla o "alisamento" da superfície gerada; (b) uma função de estimação com propriedades de suavização do fenômeno. O raio de influência define a área centrada no ponto de estimação  $u$  que indica quantos eventos  $u_i$  contribuem para a estimativa da função intensidade  $\lambda$  (CÂMARA & CARVALHO, 2004).

## 2.2 Teste de Kolmogorov-Smirnov

O Teste de Kolmogorov-Smirnov (KS) é um teste estatístico que pode ser aplicado na análise de processos pontuais para comparar a distribuição observada de eventos com uma distribuição teórica, como a hipótese de Completa Aleatoriedade Espacial (CSR). Ele mede a diferença entre as distribuições acumuladas observada e esperada e fornece uma estatística que indica se essa diferença é estatisticamente significativa. Se o valor do teste for alto, rejeita-se a hipótese de que a distribuição dos pontos segue o padrão teórico (BADDELEY, RUBAK, & TURNER, 2015).

Esse teste é usado para verificar se uma distribuição observada de pontos difere significativamente da distribuição esperada sob CSR, sendo útil para validar ou rejeitar a hipótese de aleatoriedade espacial. A estatística de teste é:

$$D = \sup_x |F_n(x) - F(x)|, \quad (2)$$

na qual  $D$  é a maior diferença entre as distribuições acumuladas observada e teórica,  $F_n(x)$  é a função de distribuição empírica dos dados observados e  $F(x)$  é a função de distribuição acumulada da hipótese teórica (sob CSR). O valor de  $D$  é comparado com valores críticos para decidir se rejeitamos a hipótese nula (BADDELEY, RUBAK, & TURNER, 2015).

## 2.3 Função K de Ripley

A Função K de Ripley é amplamente utilizada para avaliar padrões espaciais e testar a hipótese de CSR em processos pontuais. Ela calcula a quantidade média de pontos encontrados dentro de uma determinada distância  $h$  a partir de cada ponto do processo,

comparando-o com o número esperado de pontos sob a hipótese de aleatoriedade completa (BADDELEY, RUBAK, & TURNER, 2015).

Para um processo completamente aleatório, a Função K deve crescer linearmente com  $h^2$ . Desvios acima dessa linha indicam uma tendência de aglomeração (excesso de pontos dentro da distância  $h$ ), enquanto desvios abaixo indicam repulsão. A Função K é útil em várias escalas, pois permite avaliar a presença de padrões espaciais em diferentes níveis de distância (DIGGLE, 2013). Ela é definida como:

$$\lambda K(h) = E(\# \text{ eventos contidos a uma distância } h \text{ de um evento arbitrário})$$

em que  $\#$  está associado ao número de eventos,  $E(\ )$  é o operador de estimativa, e  $\lambda$  é a intensidade ou número médio de eventos por unidade de área, assumida constante na região (CÂMARA & CARVALHO, 2004).

Uma estimativa de  $K(h)$  é:

$$\hat{K}(h) = \frac{A}{n^2} \sum_i^n \sum_{j, i \neq j}^n \frac{I_h(d_{ij})}{w_{ij}}, \quad (3)$$

na qual  $A$  é a área da região,  $n$  é o número de eventos observados,  $I_h(d_{ij})$  é uma função indicatriz cujo valor é 1 se  $(d_{ij}) \leq h$  e 0 caso contrário, e  $w_{ij}$  é a proporção da circunferência do círculo centrado no evento  $i$  que está dentro da região (correção devido ao efeito de borda) (CÂMARA & CARVALHO, 2004).

## 2.4 Modelagem

Os modelos pontuais de intensidade são uma classe de modelos na estatística espacial que se concentram em descrever a intensidade de um processo pontual em diferentes regiões do espaço. A intensidade  $\lambda(s)$  é uma função que indica a densidade esperada de pontos em uma localização  $s$ , sendo um elemento central na modelagem de padrões espaciais. Esses modelos são amplamente utilizados para analisar a distribuição espacial de eventos como focos de incêndio, surtos de doenças ou crimes em uma cidade, onde a intensidade reflete a probabilidade de ocorrência de eventos em diferentes partes do espaço (DIGGLE, 2013).

A intensidade  $\lambda(s)$  é definida como a taxa esperada de eventos por unidade de área no ponto  $s$ , dada por:

$$\lambda(s) = \lim_{\Delta s \rightarrow 0} \frac{E[N(\Delta s)]}{|\Delta s|}, \quad (4)$$

em que  $N(\Delta s)$  é o número de pontos em  $\Delta s$ ,  $|\Delta s|$  é a área da região  $\Delta s$  e  $E[N(\Delta s)]$  é o valor esperado de eventos em  $\Delta s$ . Se  $\lambda(s)$  for constante em toda a região de interesse, o processo é dito homogêneo, caso contrário, é inhomogêneo (BADDELEY, RUBAK, & TURNER, 2015).

Existem diversos modelos pontuais que são utilizados na estatística espacial para descrever e analisar padrões de pontos em um espaço geográfico, sendo os mais utilizados: Processo

de Poisson; Modelos de Aglomeração; Modelos de Repulsão; Processos Pontuais Marcados. Esses modelos utilizam como parâmetros e estimativas as funções de intensidade e dependência espacial (ILLIAN, PENTTINEN, STOYAN, & STOYAN, 2008).

O Processo de Poisson é o modelo mais simples e assume Completa Aleatoriedade Espacial (CSR), onde os pontos são independentes e têm probabilidade constante de ocorrer em qualquer lugar da região de estudo. Algumas de suas propriedades é que não há interação entre os pontos (nem atração, nem repulsão) e a intensidade  $\lambda$  é constante no caso homogêneo ( $\lambda(s) = \lambda$ ). No caso inhomogêneo permite-se que a intensidade  $\lambda(s)$  varie espacialmente, sendo modelada como uma função de covariáveis espaciais  $X(s)$ :

$$\lambda(s) = \exp(\beta_0 + \beta_1 X_1(s) + \beta_2 X_2(s) + \dots + \beta_p X_p(s)),$$

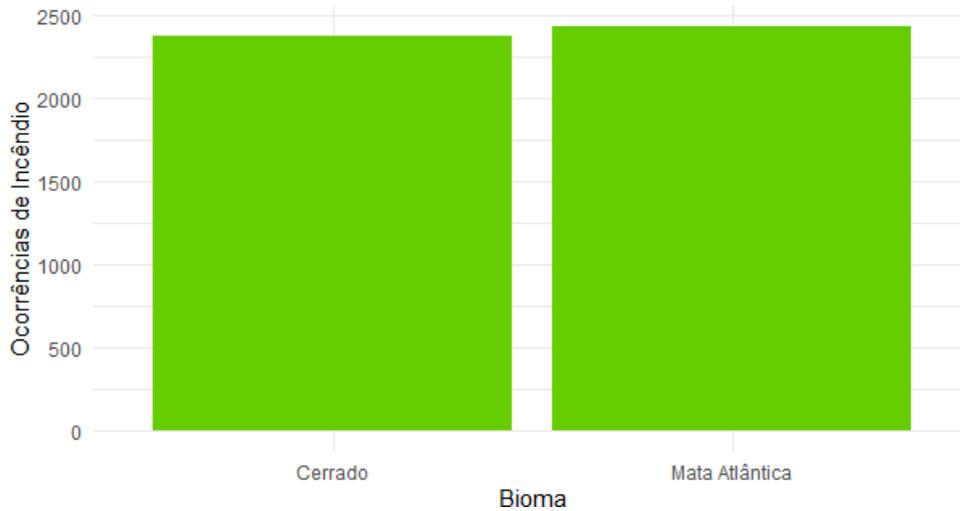
na qual  $\beta_i$  são os coeficientes associados às covariáveis (ILLIAN, PENTTINEN, STOYAN, & STOYAN, 2008).

Para comparar modelos de Poisson homogêneo com inhomogêneo se faz necessário a utilização do Critério de AIC (Akaike Information Criterion), amplamente utilizado na seleção de modelos estatísticos, incluindo modelos pontuais. Ele equilibra a qualidade do ajuste do modelo com sua complexidade, penalizando o uso de muitos parâmetros. O AIC é calculado pela fórmula  $AIC = -2 \log(L) + 2k$ , em que  $L$  é a verossimilhança do modelo ajustado e  $k$  é o número de parâmetros do modelo. Modelos com valores menores de AIC são preferíveis, pois indicam um bom equilíbrio entre ajuste e simplicidade (AKAIKE, 1974).

### 3. Aplicação

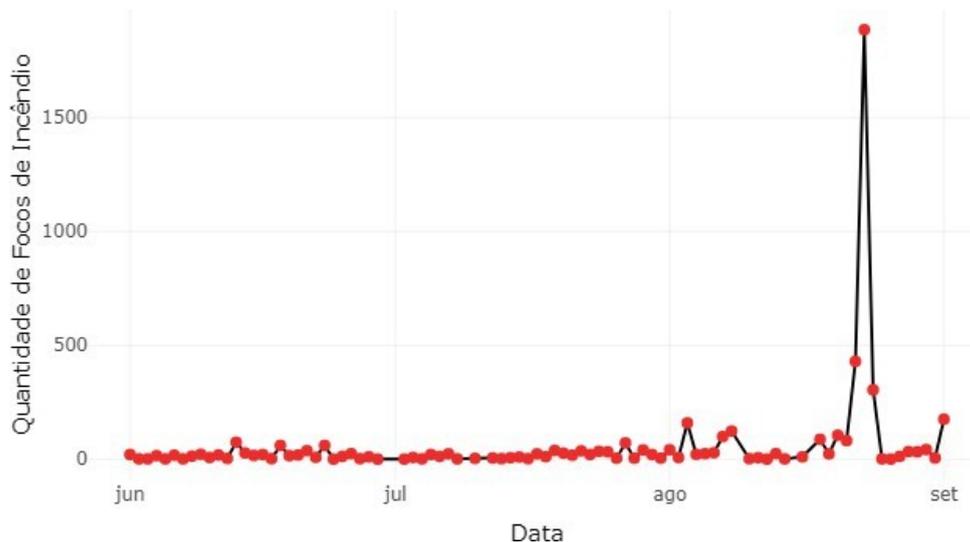
O estado de São Paulo é composto pelas formações vegetais características do Cerrado, que corresponde a 32,7% da área estadual, e da Mata Atlântica, equivalente a 67,3%. A partir da Figura 1, nota-se que estes biomas foram afetados de maneira equivalente pelos focos de incêndio, entretanto, pode-se observar também que existe uma leve diferença entre eles, o que faz com que a Mata Atlântica seja o bioma mais afetado pelos incêndios no estado. Vale destacar que a Mata Atlântica e o Cerrado são considerados *hotspots* (ambientes com alta biodiversidade, e altamente ameaçados pela ação humana na natureza), pois sofreram grandes perdas de habitats, com isso, possuem um alto risco de desaparecer.

Figura 1: Gráfico de barras para os focos de incêndio nos biomas do estado de São Paulo.



A Figura 2 expõe por meio de um gráfico de linhas, a quantidade de incêndios ocorridos durante o período de estudo, referente aos meses de junho a setembro de 2024. Percebe-se que nos primeiros meses (junho e julho) a quantidade de incêndios no estado foi baixa, apresentando uma constância na ocorrência de focos ao longo dos dias. Ao chegar no fim do mês de agosto, pode-se observar um aumento preocupante nos focos de incêndio com base no registro de mais de 1500 ocorrências em um único dia. Este aumento pode estar atrelado à estação seca no estado, que dura de maio a agosto, sendo agosto o mês com menor número de dias com precipitação.

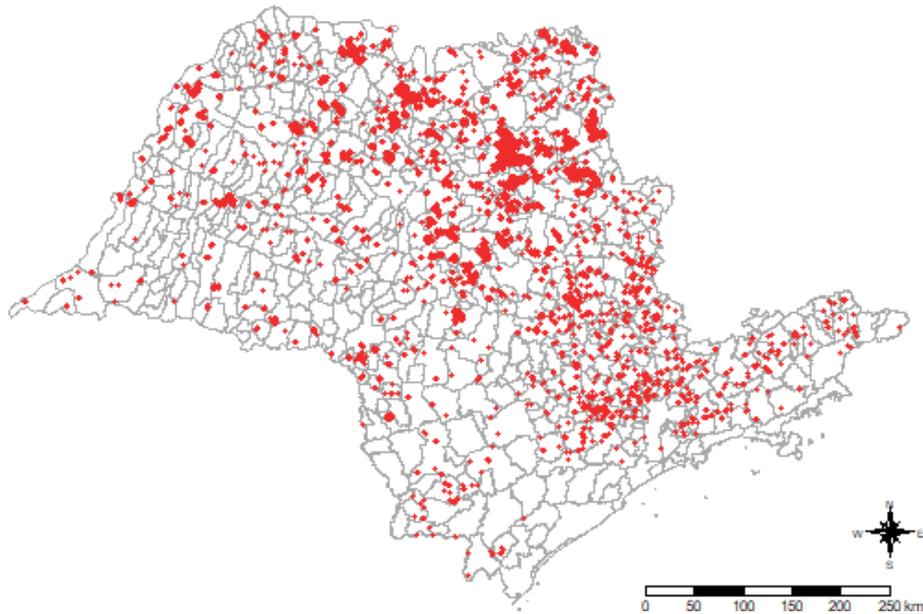
Figura 2: Gráfico de linha com pontos para a quantidade de focos de incêndio durante o período estudado.



Com base no mapa da Figura 3, nota-se que a maior densidade de focos parece estar concentrada na região nordeste do estado, possivelmente em áreas de vegetação mais suscetíveis, como biomas de transição entre o cerrado e florestas. Além disso, percebe-se a presença de focos espalhados em quase todo o estado, porém, algumas áreas apresentam

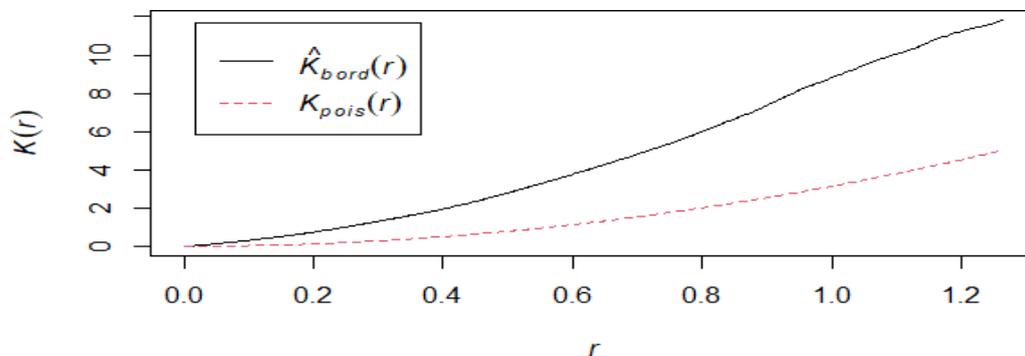
menor incidência, como por exemplo a região metropolitana de São Paulo, que é mais urbanizada. Muitas dessas ocorrências podem estar relacionadas a práticas agrícolas, como queimadas para limpeza de terrenos ou expansão de áreas cultiváveis.

Figura 3: Mapa para a distribuição dos focos de incêndio no estado de São Paulo.



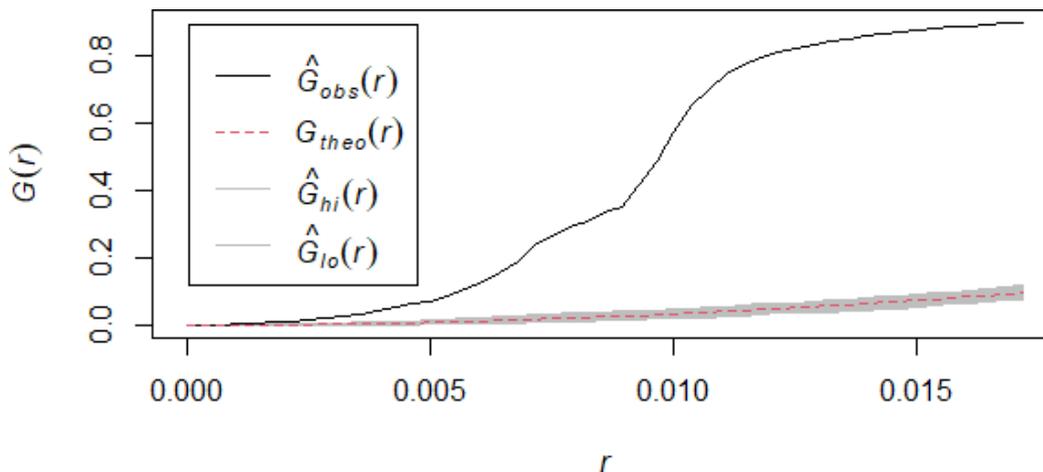
A partir da Figura 4 que mostra o gráfico da função K de Ripley, nota-se que a função observada ( $K_{bord}(r)$ ) está acima da linha de referência do padrão aleatório ( $K_{pois}(r)$ ). Isso indica que os focos de incêndio estão agregados em pequenas escalas, ou seja, existem agrupamentos de incêndios em proximidade. Além disso, percebe-se que conforme a distância aumenta, a linha preta permanece acima da linha vermelha, sugerindo que o padrão de agregação se mantém em diferentes escalas espaciais. Com isso, a distribuição dos focos de incêndio não é aleatória, pois evidencia um padrão de agrupamento.

Figura 4: Gráfico da função K de Ripley.



Com base na Figura 5, percebe-se que a função observada ( $G_{obs}(r)$ ) desvia consideravelmente da função teórica ( $G_{theo}(r)$ ), especialmente para pequenas distâncias. Isso sugere que a distribuição espacial dos focos de incêndio não segue um padrão completamente aleatório. Além disso, nota-se que a linha preta ( $G_{obs}(r)$ ) ultrapassa os limites do intervalo de confiança ( $G_{hi}(r)$  e  $G_{lo}(r)$ ), indicando que a hipótese de Completa Aleatoriedade Espacial (CSR) deve ser rejeitada. Com isso, tem-se indícios para acreditar que os focos de incêndio seguem um padrão de agrupamento espacial, especialmente em curtas distâncias.

Figura 5: Gráfico do teste de Kolmogorov-Smirnov para a completa aleatoriedade espacial.



A partir da Tabela 2, nota-se que os modelos 1 e 2 possuem AIC similares, sugerindo que ambos apresentam desempenhos quase idênticos em termos de ajuste e complexidade. Além disso, pode-se observar que o modelo 3 possui o menor valor de AIC, indicando que ele apresenta o melhor ajuste entre os modelos avaliados, apesar de ser potencialmente mais complexo.

Tabela 2: Critério de informação AIC dos modelos ajustados.

Modelo 1	Modelo 2	Modelo 3
-35572,290	-35572,580	-37413,860

Com base na Tabela 3, percebe-se que os coeficientes estimados para o intercepto e  $y$  são estatisticamente significativos e apresentam impacto substancial e preciso sobre a variável dependente. O intercepto representa o valor esperado do número de focos de incêndio quando todas as variáveis explicativas são iguais a zero. Neste caso, quando  $y = 0$ , espera-se, em média, cerca de 14,610 focos de incêndio.

O coeficiente de  $y$  indica que para cada aumento de uma unidade na variável  $y$ , o número esperado de focos de incêndio aumenta em 0,450. A relação positiva entre  $y$  e os focos de incêndio sugere que conforme  $y$  aumenta, os focos de incêndio também tendem a aumentar. Isso pode ser relevante para planejamentos de prevenção, especialmente em períodos críticos do ano, como as épocas de seca.

Tabela 3: Métricas do modelo 3.

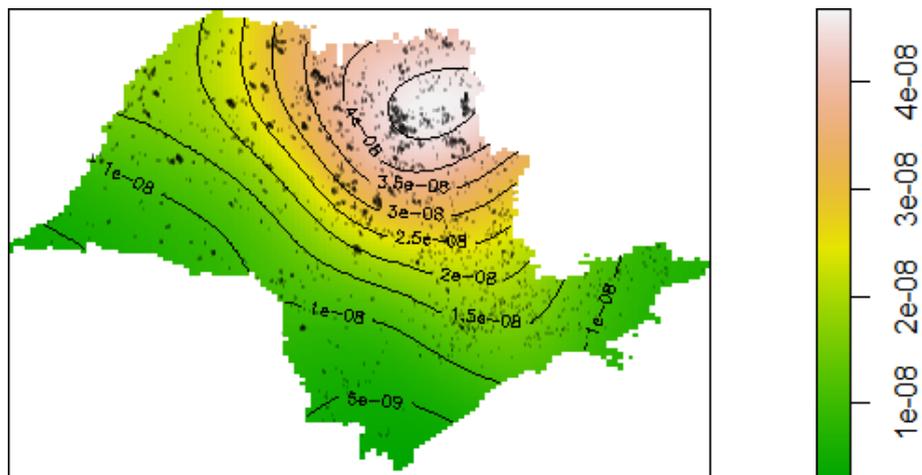
Parâmetro	Estimativa	Erro Padrão	IC 95% Inferior	IC 95% Superior	Valor Z
Intercepto	14,610	0,241	14,137	15,082	60,625***
y	0,450	0,011	0,428	0,472	40,437***

\*\*\* significativo a 0,1%.

O mapa de contorno da Figura 6 mostra a intensidade de pontos por unidade de área, a partir dele pode-se observar que a maior concentração de focos de incêndio (áreas em rosa) está localizada na região norte do estado. As áreas verdes, que indicam menor intensidade de incêndios, abrangem o sudoeste e sul do estado, regiões possivelmente menos afetadas por focos de incêndio. As isolinhas representam níveis constantes de intensidade de focos.

Quanto mais próximas essas linhas estão entre si, maior a variação da intensidade em uma área menor, o que indica uma concentração mais localizada dos focos. Essa distribuição espacial pode estar relacionada a fatores como: clima seco ou sazonalidade em determinadas áreas; uso do solo, como presença de áreas agrícolas ou florestais; proximidade de regiões urbanas, que podem ter menor incidência devido à menor cobertura vegetal.

Figura 6: Mapa de contorno para a intensidade de pontos por unidade de área.



#### 4. Conclusão

Com base nos objetivos traçados, é possível concluir que a análise espacial dos focos de incêndio ocorridos no estado de São Paulo durante o período de junho a setembro de 2024, forneceu importantes subsídios para compreender os padrões de ocorrência desses eventos.

Inicialmente, a análise descritiva demonstrou que os biomas Mata Atlântica e Cerrado, altamente ameaçados, foram os mais afetados, sendo a região nordeste do estado particularmente vulnerável. Adicionalmente, os testes estatísticos e a modelagem espacial

confirmaram que a distribuição dos focos de incêndio não segue um padrão aleatório, rejeitando a hipótese de Completa Aleatoriedade Espacial (CSR).

A utilização de ferramentas como a Função K de Ripley e o Teste de Kolmogorov-Smirnov evidenciou um padrão de agrupamento em curtas distâncias, sugerindo a presença de fatores subjacentes que favorecem a concentração de incêndios em determinadas regiões. O ajuste dos modelos indicou a capacidade de prever áreas mais propensas a incêndios, uma contribuição valiosa para estratégias de mitigação e alocação de recursos de combate.

Portanto, o estudo alcançou seus objetivos ao identificar padrões de distribuição, testar hipóteses e ajustar modelos preditivos, reforçando a importância da estatística espacial como ferramenta essencial para o entendimento e manejo dos focos de incêndio. As descobertas podem subsidiar políticas públicas mais eficazes e ações preventivas no contexto da preservação ambiental.

## Referências

1. Akaike, H. (1974). A new look at the statistical model identification. *IEEE transactions on automatic control*, 19(6), 716-723.
2. Ambiente, M. D. (2024). *Monitoramento dos Focos de Queimadas*. Fonte: INPE: <https://queimadas.dgi.inpe.br/queimadas/portal>
3. Baddeley, A., Rubak, E., & Turner, R. (2015). *Spatial point patterns: methodology and applications with R*. CRC press. CÂMARA, G., & CARVALHO, M. S. (2004). *Análise espacial de eventos*. Brasília: EMBRAPA.
4. Cressie, N. (2015). *Statistics for spatial data*. John Wiley & Sons.
5. Diggle, P. J. (2013). *Statistical analysis of spatial and spatio-temporal point patterns*. CRC press.
6. IBAMA. (2024). *Queimadas e incêndios florestais*. Fonte: Governo Federal: <https://www.ibama.gov.br/queimadas>
7. Illian, J., Penttinen, A., Stoyan, H., & Stoyan, D. (2008). *Statistical analysis and modelling of spatial point patterns*. John Wiley & Sons.
8. INPE. (2024). *BDQUEIMADAS*. Fonte: terrabrasilis: <https://terrabrasilis.dpi.inpe.br/queimadas/bdqueimadas/#exportar-dados>