

Simulação de Incêndios Florestais via Modelos Epidemiológicos em Grafos

Polyana Graf Finamor Correia¹, Jefferson Elbert Simões¹

¹Programa de Pós-Graduação em Informática
Universidade Federal do Estado do Rio de Janeiro (UNIRIO)
Caixa Postal 56.011 – 22.290.970 – Rio de Janeiro – RJ – Brasil

polyanagraf@edu.unirio.br, jefferson.simoese@uniriotec.br

Abstract. *This paper explores the prediction of trajectory and expansion potential of wildfires in heterogeneous forests. Our proposed methodology consists of modeling the target area as a finite graph following a regular 2D grid topology, each node representing a specific terrain condition, over which wildfires propagate according to a heterogeneous adaptation of the well-known SIR epidemiological model. As a proof of concept, we performed multiple computer simulations for two distinct topologies and initial random locations for wildfires in each configuration. Our results highlight the model's ability to simulate fire propagation under various conditions, offering potential for theoretical analysis and aiding in the development of fire containment strategies.*

Resumo. *Este estudo explora a previsão da trajetória e da expansão potencial de incêndios em florestas heterogêneas. Nossa proposta metodológica consiste em modelar a área-alvo como um grafo finito seguindo uma topologia regular de grade 2D, onde cada nó representa uma condição específica de terreno, sobre os quais incêndios se propagam conforme uma adaptação heterogênea do notório modelo epidemiológico SIR. Como prova de conceito, realizamos diferentes simulações computacionais para duas topologias distintas com focos iniciais aleatórios. Nossos resultados destacam a capacidade do modelo de simular a propagação do fogo sob diversas condições, oferecendo potencial para análise teórica e auxiliando no desenvolvimento de estratégias de contenção.*

1. Introdução

Incêndios florestais podem ser definidos como ocorrências não controladas de fogo que incidem sobre qualquer forma de vegetação, podendo ser provocadas de forma natural, intencional ou por negligência [de Castro et al. 2006, Duarte 2022]. Por outro lado, “queimadas” podem ser associadas a práticas de queima controlada realizadas pela ação antrópica [Duarte 2022]. Contudo, apesar da divergência semântica, ambos são extremamente prejudiciais para a fauna e flora dos locais afetados, não sendo raro que erros ocorram no processo de “queimada” e o fogo em questão chegue a proporções maiores que as previstas. Assim, no cenário atual do Brasil, o escalonamento dos registros de ocorrências desse tipo de evento vem se tornando tema recorrente em debates governamentais e pesquisas acadêmicas, pois além de gerar a fragmentação de habitats e a redução de biodiversidade nos biomas afetados, são eventos comprovadamente prejudiciais à saúde pública [Ferro et al. 2020].

De acordo com [Ferro et al. 2020], a poluição atmosférica advinda do processo de queimada é responsável não apenas pelo aumento da taxa de morbimortalidade por doenças respiratórias, mas também pela ocorrência de efeitos deletérios no coração e no pulmão em alguns casos. [de Oliveira Alves et al. 2017] afirma ainda que o problema pode chegar a nível genético, visto que “as partículas das queimadas ao entrarem nos pulmões aumentam a inflamação, o estresse oxidativo e provocam danos genéticos nas células de pulmão humano. O dano no DNA é tão grave que provoca incapacidade de sobrevivência, ou perda do controle celular causando uma reprodução desordenada evoluindo para câncer de pulmão.”

Neste sentido, faz-se necessário elaborar com certa urgência estratégias e equipamentos que suprimam o espalhamento do fogo e da fumaça oriundos deste processo. Em 2024, foram registrados cerca de 29,7 milhões de hectares queimados entre janeiro e novembro, caracterizando a maior extensão de território queimado em seis anos [Nascimento 2024]. No entanto, a propagação de incêndios ocorre de forma não-linear e complexa, considerando a interação entre processos bióticos e abióticos, tendo como quatro fatores principais os aspectos climáticos e antrópicos, fatores topográficos e características da vegetação [Duarte 2022].

Notando a complexidade do problema abordado, este trabalho propõe uma nova estratégia para prever a trajetória e o potencial de expansão de incêndios florestais em florestas heterogêneas, explorando a aplicação de técnicas das áreas de Ciência de Redes e Epidemiologia, em particular o conhecido modelo epidemiológico SIR (suscetível-infectado-recuperado). O restante deste artigo está estruturado da seguinte forma: na seção 2 apresenta-se a revisão bibliográfica dos trabalhos relacionados à temática da pesquisa; nas seções 3 e 4 explica-se o modelo proposto e apresentam-se os testes realizados para sua validação; por fim na seção 5 são abordadas as conclusões e os futuros desafios do projeto.

2. Trabalhos Relacionados

2.1. Incêndios e Queimadas

A modelagem do fogo permanece um desafio recorrente na Computação, tendo uma vasta quantidade de trabalhos focados em desenvolver métodos melhores para prever o “*next day’s fire danger*”, i.e., o nível de risco de incêndio estimado para o dia seguinte, geralmente baseado em condições meteorológicas como temperatura, umidade, vento e precipitação, mas sem considerar fatores de vegetação, ou atividade humana [Kondylatos et al. 2022]. Tais riscos costumam ser calculados usando índices como o *Fire Weather Index* (FWI), que avaliam a probabilidade de ocorrência e propagação de incêndios, mas se mostram abertos a erros significativos, considerando a natureza intrinsecamente estocástica de incêndios florestais reais.

Técnicas de Inteligência Artificial têm sido utilizadas nesse contexto para tais predições. Por exemplo, [Duarte 2022] infere a Suscetibilidade à Incêndios e Queimadas (SIQ) a partir de dados de sensoriamento remoto, através de um método misto de aprendizagem de máquina e inferência fuzzy. [Kondylatos et al. 2022] utiliza dados em três modalidades (instância, temporal e espaço-temporal) e emprega algoritmos de aprendizagem profunda para processar diferentes entradas e obter uma saída em forma de classificação binária ao fim do processo.

Apesar da recorrência do tema, modelos eficientes que foquem na previsão da trajetória adotada pela frente do fogo ainda se mostram escassos. Dentre os modelos encontrados, o estudo de [Brasiel and Lima 2023], propõe o uso de autômatos celulares como ferramenta para modelar a propagação de incêndios florestais em ambientes heterogêneos. Esta abordagem permitiu simular as dinâmicas de propagação considerando a interação entre diferentes tipos de vegetação, vetores de vento e a influência de barreiras naturais, como rios, sem necessariamente utilizar dados de sensoriamento remoto, como nos demais estudos citados. Apesar do desafio em validar o modelo quanto a comparações reais inicialmente, o estudo traz à luz a importante comparação entre modelos homogêneos, que assumem uma cobertura vegetal uniforme em toda a área simulada e são úteis para estudos específicos, e modelos heterogêneos, que apresentam maior fidelidade ao mundo real uma vez que consideram a distribuição espacial de diferentes tipos de vegetação e elementos naturais, sendo mais compatíveis a biomas como o cerrado brasileiro. Contudo, o modelo apresenta limitações como a ausência de representação da dinâmica de recuperação da vegetação após a queima, um aspecto crucial considerando a notável resiliência do Cerrado após incêndios, e a falta de discussão sobre a eficiência computacional do modelo proposto, um fator determinante para aplicações práticas, especialmente em simulações de larga escala que seriam necessárias para gerenciamento ambiental e tomada de decisões em criações de estratégias de contenção.

2.2. Modelos Epidemiológicos

Esta subseção se propõe a explicar primeiramente as definições que caracterizam um modelo epidemiológico, bem como o funcionamento do modelo SIR, a fim de criar uma contextualização adequada antes da devida apresentação da proposta.

Modelos epidemiológicos são técnicas matemáticas de modelagem e análise, utilizadas no estudo e compreensão da disseminação de doenças em populações. Apesar deste foco, os preceitos fundamentais destes modelos também podem ser aplicados a contextos de saúde cujas dinâmicas não são estritamente epidêmicas, como prevalência de obesidade [Christakis and Fowler 2007], e fenômenos de espalhamento de naturezas diversas, como propagação de malwares em redes de computadores [Chernikova et al. 2023], disseminação de desinformação em redes sociais [Govindankutty and Gopalan 2024] e adoção de inovações tecnológicas [Valente 1996].

Historicamente, modelos epidemiológicos são baseados em duas premissas fundamentais: compartimentalização e mistura homogênea [Barabási and Pósfai 2016]. *Compartimentalização* se refere à classificação dos indivíduos em diferentes estados caracterizando estágios únicos de avanço da doença, com transições individuais entre estes estados ocorrendo em função de eventos como infecção e recuperação. Modelos diferem em função de quais estados, transições e eventos são considerados, cada um se adequando à modelagem de doenças específicas em função de especificidades do fenômeno epidêmico. Já a premissa de *mistura homogênea* assume que contatos par-a-par entre indivíduos ocorrem de maneira igualitária, sem favorecimento a nenhum tipo de contato específico.

A combinação destas premissas evita a necessidade de se conhecer a rede de contatos precisa pela qual a doença se espalha e, naturalmente, favorece a utilização de abordagens de campo médio, que são particularmente adequadas a técnicas de

análise baseadas em equações diferenciais, seja para modelos determinísticos ou estocásticos [Kendall 1956]. Para ilustrar isso, é interessante analisar em detalhes um dos modelos mais tradicionais da área, conhecido como *modelo SIR*.

2.3. Modelo SIR

O modelo SIR (suscetível-infectado-recuperado) prevê a utilização de três compartimentos para os indivíduos [Kermack and McKendrick 1927]: no estado *infectado*, o indivíduo porta a doença e pode infectar outros indivíduos, enquanto no estado *suscetível* (S), o indivíduo não porta a doença mas está sujeito a adquiri-la via contato com um indivíduo infectado. O estado *removido* ou *recuperado* (R) representa indivíduos anteriormente infectados, mas que não portam mais a doença (logo não estão mais infecciosos) nem podem readquiri-la, representando em geral uma recuperação com imunidade adquirida (embora a remoção de indivíduos do sistema por outros eventos também possa ser representada por este estado). Na Figura 1 podemos observar o diagrama que ilustra este fluxo.




Figura 1. Diagrama de fluxo do modelo SIR

As transições dos indivíduos entre estes estados são baseadas nas interações entre eles e em dois parâmetros principais: a taxa de infecção (β) e a taxa de recuperação (γ). Na versão tradicional do modelo, que utiliza uma abordagem de campo médio, a evolução da população em cada compartimento é descrita por um sistema de equações diferenciais:

$$\begin{aligned}\frac{dS}{dt} &= -\frac{\beta SI}{N}, \\ \frac{dI}{dt} &= \frac{\beta SI}{N} - \gamma I, \\ \frac{dR}{dt} &= \gamma I.\end{aligned}$$

Desta forma, através da solução analítica ou numérica deste sistema de equações, é possível prever a evolução temporal da distribuição da população entre os diferentes estados, fornecendo percepções interessantes sobre o comportamento da disseminação de doenças em diferentes populações.

3. Proposta

Um incêndio florestal segue um padrão de desenvolvimento em três etapas distintas: a ignição inicial, onde o fogo começa pequeno e com propagação relativamente lenta; a fase de aceleração, na qual a largura da frente de fogo aumenta e sua taxa de propagação acelera; e o estado estacionário, quando o fogo atinge uma taxa de propagação estável que corresponde às condições predominantes de combustível, clima e topografia [Sullivan and Gould 2020].

Esta dinâmica de propagação é similar ao processo de disseminação de doenças proposto pelo modelo SIR, o que permite sua modelagem através de uma adaptação do modelo. Realizando um trabalho simples de abstração, podemos associar a forma de contato entre indivíduos suscetíveis e infectados à propagação do fogo através do contato entre áreas em chamas e áreas com potencial para queima. A taxa de progressão do fogo, que pode ser medida tanto pelo tempo necessário para percorrer uma distância conhecida, quanto pela distância percorrida em um tempo determinado [Sullivan and Gould 2020] é outro fator onde encontramos um paralelo, neste caso com a taxa de transmissão de doenças do modelo epidemiológico.

Assim, na proposta em questão foram realizados experimentos em redes de Grid 2D, com o intuito de simular um espaço cartesiano onde fosse possível obter uma visualização clara dos terrenos analisados. Na criação da rede foram atribuídas características distintas a 4 tipos de nós, pois como trazido por [Brasiel and Lima 2023] a inflamabilidade em diferentes tipos de vegetação é variada.

Esta variação seguiu a lógica de representação de [Brasiel and Lima 2023] ao categorizar a suscetibilidade ao fogo de cada tipo de vegetação dentro de um Cerrado. Desta forma, os nós são divididos em: nós laranja (florestas úmidas), que possuem baixa chance de infecção e são similares a indivíduos com alta resistência a uma doença; nós azuis (matas de transição) apresentam probabilidade moderada de propagação; e nós verdes (vegetação seca), que possuem alta probabilidade de inflamar. Por fim, os rios, representados por nós vermelhos, atuam como barreiras naturais à propagação do fogo nas simulações, similar a indivíduos imunes em um modelo epidemiológico. Na Figura 2 é possível observar um exemplo desta distribuição.

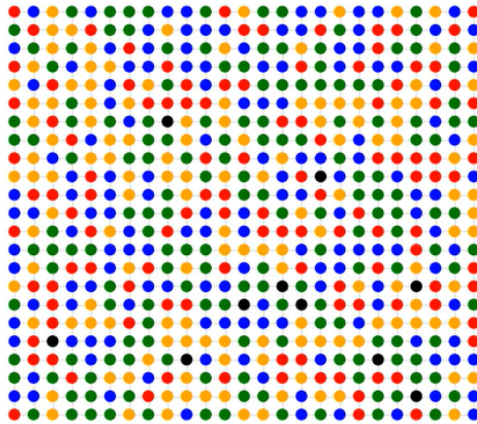


Figura 2. Exemplo de configuração inicial para o modelo.

A dinâmica de transmissão e recuperação no modelo é baseada em probabilidades, mas diferente do modelo SIR padrão, o cálculo dessa probabilidade foi adaptado para se adequar melhor aos diferentes terrenos. Para cada nó suscetível, calcula-se a probabilidade de infecção com base na suscetibilidade da cor do nó e na taxa de transmissão beta, considerando o número de vizinhos infectados. Paralelamente, para cada nó infectado, verifica-se a probabilidade de recuperação em cada passo temporal, comparando um número gerado aleatoriamente com o parâmetro gamma. Esta é

uma abordagem fundamentalmente baseada em modelos epidêmicos modernos em redes [Pastor-Satorras and Vespignani 2001], sendo as principais diferenças a especificação de uma topologia regular para a rede subjacente e a heterogeneidade da taxa de infecção (i.e. propagação do fogo) em função do tipo de vegetação representada.

Por fim, o modelo inicia sua simulação considerando duas formas de infecção: “Random”, em que os nós infectados inicialmente são selecionados aleatoriamente, e “Manual”, que permite a escolha específica dos nós a serem infectados. A partir dessa configuração inicial, a propagação do fogo ocorre conforme a suscetibilidade de seus vizinhos, até atingir um estado estacionário ao final dos passos temporais (steps). Para tornar a representação visual da simulação mais clara, os nós onde o fogo está ativo são representados na cor preta, enquanto aqueles por onde o fogo já passou, mas se extinguiu, aparecem em cinza.

Esta proposta possui alguns diferenciais relevantes em relação a modelos anteriores para previsão de incêndios. Em particular, os trabalhos de [Duarte 2022] e [Kondylatos et al. 2022] têm como objetivo prever o início de incêndios, não sua trajetória, sendo aplicáveis em escalas de tempo mais longas que a duração em um incêndio em atividade típico. A utilização de um modelo estocástico, em oposição à dinâmica determinística de [Brasiel and Lima 2023], permite um processo mais flexível de representação de cenários reais, nos quais não é possível medir ou controlar todas as variáveis relevantes.

4. Testes e Resultados

A fim de testar seu funcionamento, o modelo foi rodado em uma máquina com processador Intel(R) Core(TM) i5-7200U CPU @ 2.50GHz com 8 GB de RAM, 2GB de placa de vídeo e 2 núcleos.

Inicialmente foram criadas redes aleatórias com diferentes probabilidades de surgimento de nós. Assim, cada categoria de nó possuía mais ou menos chances de aparecer no Grid. Uma vez que terrenos reais não seguem normas de equilíbrio claras quanto a sua distribuição, a variação de ocorrência de determinadas “cores” se mostrou interessante para diferentes análises. Dentro das primeiras simulações propostas ocorreram variações no número inicial de nós infectados, número total de nós da rede (que variaram de 100 a 2500 nós), probabilidade de ocorrência de determinados nós e número de passos temporais.

Subsequentemente, adaptamos o modelo para que ele realizasse ao menos 50 simulações, mantendo o mesmo mapa e os mesmos nós iniciais a cada vez que o sistema fosse iniciado. Retornando ao final um arquivo com a contagem de nós em cada um dos estados por step, bem como uma animação gerada com base na análise de todas as simulações decorrentes a partir da criação de uma matriz de probabilidade de infecção para cada nó ao longo do tempo. Para isso, calculamos a frequência com que cada nó esteve infectado ou recuperado em cada etapa da simulação e normalizamos esses valores pelo número total de execuções. O cálculo para criação desta matriz é mostrado abaixo, de forma que $N_{inf}(t, n)$ representa o número de vezes que o nó n esteve infectado no passo t , $N_{rec}(t, n)$ representa o número de vezes que o nó n esteve recuperado no passo t , e N_{total} representa o número total de simulações.

$$P_{\text{infectado}}(t, n) = \frac{N_{\text{inf}}(t, n)}{N_{\text{total}}} \quad (1)$$

$$P_{\text{recuperado}}(t, n) = \frac{N_{\text{rec}}(t, n)}{N_{\text{total}}} \quad (2)$$

Assim, obtivemos uma probabilidade acumulada de infecção e recuperação para cada nó, permitindo determinar seu estado com base em um limiar (threshold). O valor definido para este limiar no estudo foi de 50%. Caso a soma das probabilidades seja igual ou ultrapasse o valor, o nó é considerado infectado; já se a probabilidade de recuperação se iguala ou excede o limiar e o nó foi infectado anteriormente, ele é classificado como recuperado.

Os experimentos a este ponto apresentaram potencial para serem expandidos, assim o sistema foi ajustado para gerar uma rede com cerca de 10.000 nós por simulação. Mas apesar da expansão considerável da rede e do aumento no número de instanciações, o tempo total de execução das simulações foi, em média, abaixo de 8 minutos. Assim, testamos uma variação onde foram realizadas 200 simulações, ao que o código levou aproximadamente 33 minutos para ser executado. No intuito de posteriormente espelhar ambientes reais nas simulações, também foram testadas redes projetadas, como é possível observar na Figura 3.

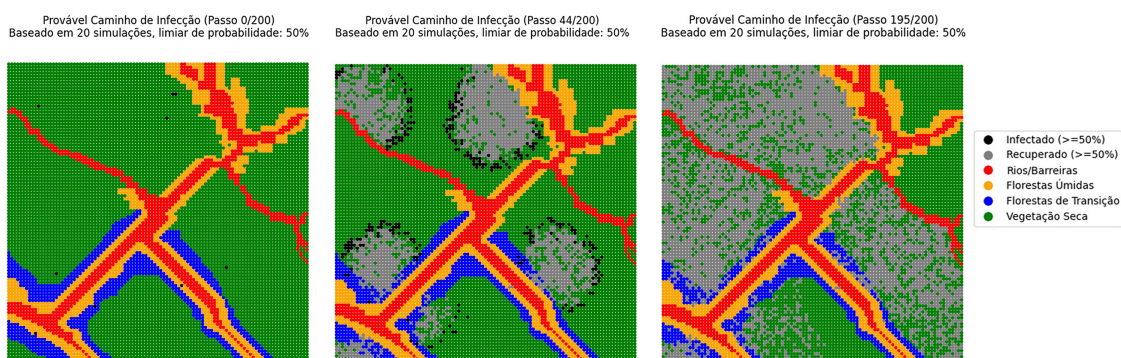


Figura 3. Exemplo de Rede Projetada. À esquerda, a configuração inicial, incluindo focos iniciais de fogo. Ao centro e à direita, estados típicos de propagação do fogo após 200 e 400 passos de simulação, respectivamente.

Alguns dos resultados em comum entre a fase inicial do modelo e a fase mais recente mostram que conforme a ocorrência de rios aumenta, a tendência de que o fogo fique limitado a locais específicos aumenta em acordo, comprovando a dificuldade de espalhamento diante de barreiras naturais, ou agentes imunes. Uma exemplificação deste padrão ocorre na Figura 4(a). Já em ambientes onde os nós vermelhos ocorrem com menos frequência, as simulações se mostraram mais favoráveis à propagação, como na Figura 4(b). Os experimentos atestaram também a variância na progressão do fogo a depender dos locais onde os primeiros focos são atribuídos, mesmo mantendo o restante dos parâmetros, bem como os diferentes resultados obtidos conforme o número de focos de incêndio iniciais é alterado.

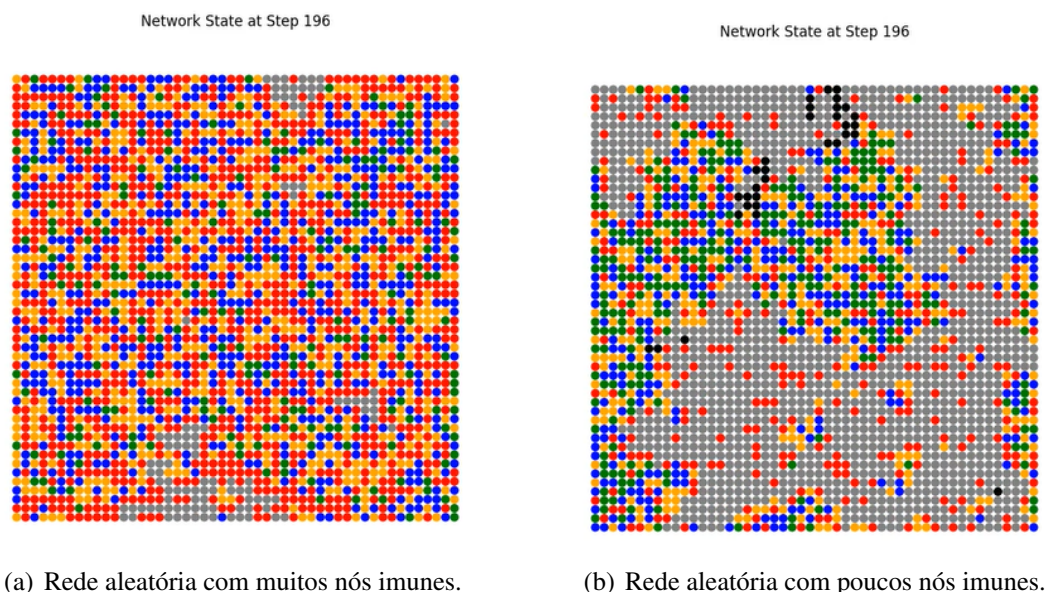


Figura 4. Dois exemplos de redes aleatórias.

O fluxo dos resultados, apesar de variar conforme o número de passos temporais simulados e do número de nós infectados, apresentou uma tendência semelhante à definida por [Sullivan and Gould 2020] em relação ao padrão de desenvolvimento de incêndios florestais, como podemos notar na Figura 5. Neste contexto, os resultados gerais do modelo adaptado apresentam grande potencial teórico para prever a trajetória de focos de incêndio em biomas com vegetações diversificadas como o Cerrado. Graças a natureza majoritariamente visual dos resultados propostos, a interpretação das previsões obtidas se torna mais democrática. E os resultados obtidos demonstraram também a versatilidade do sistema em lidar com parâmetros diferentes sem a necessidade de períodos exponenciais para sua execução. Além disso, uma vez que todos os testes foram realizados em um notebook i5 de sétima geração, com memória SSD de 446 GB, pressupõe-se que com máquinas mais potentes seu tempo de execução se mantenha aceitável mesmo com redes consideravelmente maiores.

5. Conclusões e trabalhos futuros

A modelagem inicial demonstrou que os modelos epidemiológicos possuem um vasto potencial inexplorado dentro deste tema, apresentando similaridades relevantes com o processo de propagação do fogo. A aplicação desses modelos no contexto de incêndios florestais pode fomentar o desenvolvimento de novas teorias e análises de redes voltadas para estratégias de contenção.

A proposta tem como objetivo, a longo prazo, gerar uma ferramenta útil para os órgãos que atuam na prevenção e no combate a incêndios florestais. Fato que justifica a busca por resultados visualmente intuitivos e um tempo de execução otimizado, mesmo diante de possíveis limitações de hardware. Os resultados obtidos até o momento abrem caminho para novos estudos que investiguem diferentes biomas e refinem ainda mais os fatores que influenciam a propagação do fogo.

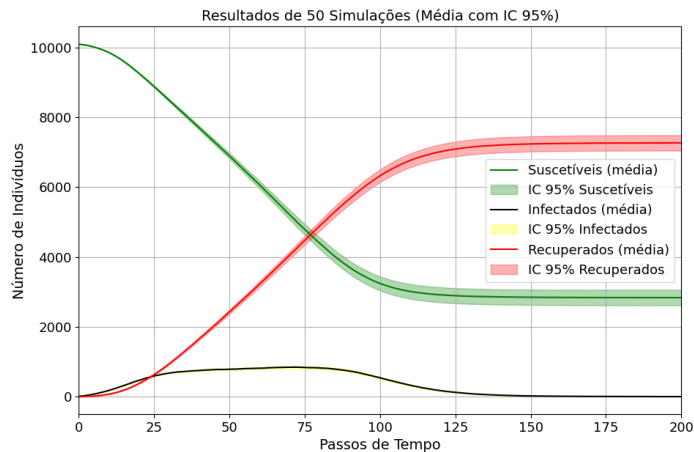


Figura 5. Proporção média de nós vulneráveis (S), em chamas (I) e queimados (R) ao longo do tempo. Regiões hachuradas representam intervalo de confiança de 95%.

Contudo, para tornar os testes mais próximos de ambientes reais, trabalhos futuros buscarão criar redes baseadas em áreas existentes como APA's ou parques nacionais para que possamos comparar o fluxo de incêndios passados, às simulações realizadas pelo modelo adaptado. Ademais, pretende-se ampliar a diversidade de vegetações consideradas no modelo, refinando a taxa de suscetibilidade de cada nó. Outros fatores, como direção do vento e topografia do terreno, também serão incorporados para aumentar a precisão da análise.

6. Agradecimentos

O presente trabalho foi realizado com o apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de financiamento 001.

Referências

- Barabási, A.-L. and Pósfai, M. (2016). *Network science*. Cambridge University Press, Cambridge.
- Brasiel, H. C. and Lima, D. A. (2023). Exploring the influence of wind, vegetation and water sources on the spread of forest fires in the brazilian cerrado biome using cellular automata. In *Anais do XIV Workshop de Computação Aplicada à Gestão do Meio Ambiente e Recursos Naturais*, pages 61–70, Porto Alegre, RS, Brasil. SBC.
- Chernikova, A., Gozzi, N., Perra, N., Boboila, S., Eliassi-Rad, T., and Oprea, A. (2023). Modeling self-propagating malware with epidemiological models. *Applied Network Science*, 8(1):52.
- Christakis, N. A. and Fowler, J. H. (2007). The spread of obesity in a large social network over 32 years. *New England Journal of Medicine*, 357(4):370–379.
- de Castro, C. F., Serra, G., Parola, J., Reis, J., Lourenço, L., and Correia, S. (2006). *Combate a Incêndios Florestais (Vol. XIII)*. Sintra: Escola Nacional de Bombeiros, 3ª edição, revista e actualizada edition. Manual de Formação Inicial do Bombeiro.

- de Oliveira Alves, N., Vessoni, A. T., Quinet, A., Fortunato, R. S., Kajitani, G. S., Peixoto, M. S., Hacon, S. d. S., Artaxo, P., Saldiva, P., Menck, C. F. M., et al. (2017). Biomass burning in the amazon region causes dna damage and cell death in human lung cells. *Scientific reports*, 7(1):10937.
- Duarte, M. L. (2022). *Previsão da suscetibilidade à incêndios e queimadas utilizando um modelo baseado em inteligência artificial e sistema de inferência fuzzy*. PhD thesis, Universidade Estadual Paulista (UNESP). Tese de Doutorado.
- Ferro, I., Santos, A. L. S., and Martins, S. M. (2020). Queimadas e doenças respiratórias. *Sociedade Brasileira de Medicina de Família e Comunidade (SBMFC)*. Material elaborado pelo Grupo de Trabalho de Problemas Respiratórios - GRESP-SBMFC. Publicado em: 10 de setembro de 2020.
- Govindankutty, S. and Gopalan, S. P. (2024). Epidemic modeling for misinformation spread in digital networks through a social intelligence approach. *Scientific Reports*, 14(1):19100.
- Kendall, D. G. (1956). Deterministic and stochastic epidemics in closed populations. In Neyman, J., editor, *Proceedings of the Third Berkeley Symposium on Mathematical Statistics and Probability, Volume 4: Contributions to Biology and Problems of Health*, pages 149–165. University of California Press.
- Kermack, W. and McKendrick, A. (1927). A contribution to the mathematical theory of epidemics. *Proceedings of the Royal Society of London. Series A, Containing Papers of a Mathematical and Physical Character*, 115(772):700–721.
- Kondylatos, S., Prapas, I., Ronco, M., Papoutsis, I., Camps-Valls, G., Piles, M., Fernández-Torres, M.-A., and Carvalhais, N. (2022). Wildfire danger prediction and understanding with deep learning. *Geophysical Research Letters*, 49(17).
- Nascimento, L. (2024). Área queimada no Brasil até novembro quase dobra em relação a 2023. <http://agenciabrasil.ebc.com.br/meio-ambiente/noticia/2024-12/area-queimada-no-brasil-ate-novembro-quase-dobra-em-relacao-2023>. Accessed: 2024-12-22.
- Pastor-Satorras, R. and Vespignani, A. (2001). Epidemic spreading in scale-free networks. *Phys. Rev. Lett.*, 86:3200–3203.
- Sullivan, A. and Gould, J. (2020). Wildland fire rate of spread. In Manzello, S., editor, *Encyclopedia of Wildfires and Wildland-Urban Interface (WUI) Fires*, pages 1095–1098. Springer, Cham.
- Valente, T. W. (1996). Network models of the diffusion of innovations. *Computational & Mathematical Organization Theory*, 2(2):163–164.