

Aplicação de técnicas de análise de séries temporais na gestão proativa de desastres no estado do Rio de Janeiro



<https://doi.org/10.56238/interdiinovationscrese-006>

Samir Batista Fernandes

Especialista em Defesa Civil - UNISUL
Mestre em Segurança e Proteção Civil - UFF
Especialista em Ciência de Dados - USP
Assessor Especial da SEDEC-RJ

RESUMO

Neste estudo, foi realizada uma análise aprofundada de séries temporais para aprimorar a gestão de desastres e o planejamento de contingência no estado do Rio de Janeiro. Utilizando técnicas de análise de séries temporais, o estudo buscou não apenas validar hipóteses preexistentes, mas também descobrir novas maneiras de tomada de decisões baseada em evidências. A análise revelou padrões sazonais distintos, principalmente entre novembro e abril, um período identificado como crítico para a implementação de estratégias de respostas eficazes. A pesquisa destacou a contribuição significativa de certas categorias de ocorrência com a tendência e

sazonalidade observadas na série temporal, oferecendo uma base sólida para a redução de incertezas no planejamento de contingências. Além disso, a possibilidade de extrapolação de resultados abre caminho para previsões mais acuradas de eventos futuros, facilitando uma resposta mais rápida e eficaz a eventos adversos. Em conclusão, o estudo serve como um modelo robusto para a gestão baseada em dados de desastres, indicando uma via para uma abordagem mais científica e eficaz no desenvolvimento e implementação de planos de contingência. Representa uma contribuição valiosa para a literatura existente, demonstrando o potencial do aprendizado de máquinas e análise de séries temporais na promoção de uma gestão de desastres mais proativa e orientada por dados.

Palavras-chave: Plano de contingência, SEDEC, ICTDEC, Data-driven.

1 INTRODUÇÃO

Nos últimos anos, a frequência e magnitude de desastres naturais e eventos adversos têm intensificado, elevando as preocupações em níveis globais e locais (CRED & UNISDR, 2018). Neste contexto, a criação de planos de contingência eficazes, embasados em evidências científicas robustas, torna-se uma necessidade premente (Perry, 2007).

A análise de séries temporais históricas, disponíveis nas bases de dados de agências de proteção e defesa civil, apresenta uma oportunidade inestimável para desvendar os padrões e tendências desses eventos adversos (Zhang et al., 2015). A grande vantagem de empregar técnicas avançadas de análise de séries temporais em vastos conjuntos de dados reside na capacidade de superar as limitações das análises estatísticas básicas, como contagem de frequências, moda e média, comumente empregadas nos registros históricos de ocorrências fornecidos por agências de proteção e defesa civil. Estas técnicas avançadas são capazes de identificar padrões complexos que podem permanecer ocultos para análises mais superficiais (Hyndman & Athanasopoulos, 2018).



Dessa forma, o uso de técnicas avançadas de séries temporais não apenas ultrapassa a análise estatística básica, mas também facilita uma tomada de decisões baseada em evidências mais sólidas, reduzindo incertezas, permitindo a validação de hipóteses e a projeção de resultados com maior precisão (Shmueli, 2010). A aplicação de técnicas de séries temporais, neste contexto, amplia ainda mais as possibilidades, permitindo previsões mais acuradas e uma resposta mais ágil e orientada por dados aos desastres.

A integração dessas análises em planos de contingência pode promover uma alocação de recursos mais eficiente, minimizando assim o impacto desses eventos adversos nas comunidades afetadas (UNISDR, 2015).

A justificativa para este estudo reside na hipótese do aumento de ocorrências nos meses de verão no estado do Rio de Janeiro e a necessidade crescente de abordagens baseadas em evidências científica para a gestão de redução de desastres ou dos eventos adversos. Além disso, a identificação de padrões sazonais e tendências pode servir como uma ferramenta vital para os tomadores de decisão, auxiliando na implementação de medidas proativas que podem salvar vidas e preservar recursos.

Este estudo buscou, portanto, contribuir para a literatura existente, fornecendo uma análise aprofundada das ocorrências de eventos adversos, com um foco particular na identificação de padrões sazonais e tendências.

O objetivo principal deste estudo foi analisar as séries temporais históricas de ocorrências atendidos por municípios do estado do Rio de Janeiro que utilizam a plataforma criada pela Secretaria Estadual de Defesa Civil do estado do Rio de Janeiro chamada de programa de registro de ocorrências – PRODEC, com o intuito de identificar padrões de sazonalidade e tendências que possam informar a criação de planos de contingência mais eficazes. Além disso, o estudo visou destacar a importância da análise de dados no desenvolvimento de estratégias de gestão de desastres baseadas em evidências, promovendo assim uma resposta mais eficaz e eficiente a eventos adversos.

O presente artigo está estruturado da seguinte maneira: a seção 2 descreverá o referencial teórico, na seção 3 será adotada a metodologia para a análise dos dados, incluindo uma descrição detalhada dos dados utilizados e das técnicas de análise empregadas. A seção 4 apresentará a análise dos dados, destacando os principais resultados em relação à sazonalidade e tendências observadas nas séries temporais. A seção 5 discutirá os resultados obtidos destacando suas implicações práticas. Finalmente, a seção 6 oferecerá uma conclusão do estudo, resumindo as principais descobertas e sugerindo possibilidades para pesquisas futuras.



2 REFERENCIAL TEÓRICO

Nesta seção, foi delineada a fundamentação teórica que sustenta este estudo, abrangendo os conceitos cruciais na gestão de desastres, utilizando a ciência de dados como uma ferramenta na redução dos riscos de desastres e as técnicas avançadas de séries temporais que foram empregadas.

2.1 CONCEITOS FUNDAMENTAIS EM GESTÃO DE DESASTRES

Na área de gestão de desastres, é fundamental entender e diferenciar conceitos-chave como ameaça, desastre, eventos adversos, vulnerabilidade e ocorrências:

- **Ameaça:** Refere-se a um evento potencialmente danoso que pode ocorrer em um futuro incerto, geralmente como resultado de fenômenos naturais ou atividades humanas (UNISDR, 2009).
- **Desastre:** É a realização de uma ameaça, onde o evento danoso ocorre, causando danos significativos e, muitas vezes, perdas humanas (CRED, 2015).
- **Eventos Adversos:** São incidentes que podem levar a desastres, geralmente identificados como sinais precoces de uma ameaça emergente (Perry, 2007).
- **Ocorrências:** Referem-se a eventos específicos que são registrados pelas agências de proteção e defesa civil, podendo ser tanto eventos adversos quanto desastres (Alexander, 2016). Cabe destacar, que no presente estudo a natureza das ocorrências atendidas por agências de proteção e defesa civil são classificadas em grupos distintos, tais como: evento adverso, vulnerabilidade, ameaça, não se aplica ou registro incompleto.
- **Vulnerabilidade:** Representa o grau de exposição e susceptibilidade de uma comunidade ou sistema frente a ameaças, sendo um componente crucial na gestão e mitigação de desastres (Cutter, 1996).

2.2 CIÊNCIA DE DADOS COMO FERRAMENTA DE APOIO

A ciência de dados surge como uma ferramenta poderosa na gestão de desastres, oferecendo técnicas avançadas que vão além das análises estatísticas tradicionais. A análise de séries temporais, uma abordagem subjacente na ciência de dados, é complementada por outras técnicas igualmente importantes, como decomposição, suavização exponencial, ARIMA, regressão, redes neurais etc.. que juntas proporcionam uma análise mais holística e profunda dos dados (Provost & Fawcett, 2013).

2.3 CONCEITOS FUNDAMENTAIS EM SERIES TEMPORAIS APLICADOS NESSA PESQUISA

- **Estacionariedade:** A estacionariedade refere-se a uma propriedade das séries temporais em que as estatísticas, como média e variância, permanecem constantes ao longo do tempo.



Isso significa que não há tendências significativas ou padrões sistemáticos que mudam com o tempo (Brockwell & Davis, 2016).

- **Série temporal:** Uma série temporal é um conjunto de observações ou dados coletados em intervalos de tempo regulares. Esses dados são organizados de forma cronológica e podem ser usados para analisar tendências e padrões ao longo do tempo (Chatfield, 2003).
- **Decomposição:** A decomposição é um processo usado para separar uma série temporal em seus componentes principais, que geralmente são tendência, sazonalidade e resíduos. A tendência representa o padrão geral de aumento ou diminuição ao longo do tempo, a sazonalidade captura variações periódicas e os resíduos são as variações não explicadas pelas tendências e sazonalidades (Hyndman & Athanasopoulos, 2018).
- **Tendência:** A tendência em uma série temporal representa a direção geral em que os dados estão se movendo ao longo do tempo. Pode ser uma tendência ascendente (aumento) ou descendente (diminuição) (Montgomery, Johnson & Gardiner, 2012).
- **Sazonalidade:** A sazonalidade em uma série temporal refere-se a variações que ocorrem em intervalos regulares de tempo, geralmente em um padrão cíclico. Por exemplo, podemos observar um aumento significativo no número de ocorrências registradas pela Defesa Civil durante os períodos de maior pluviometria, como a temporada de chuvas intensas (Wei, 2006).

3 METODOLOGIA

Os dados utilizados neste estudo foram coletados a partir da plataforma PRODEC, que agrega informações sobre eventos adversos oriundos de diversos municípios do estado do Rio de Janeiro. Durante o período de estudo, que compreende o intervalo dos anos de 2013 até 2023, um total de 70 municípios estavam registrados e ativamente contribuindo com dados para a plataforma.

Para a análise dos dados, foi utilizado Python, uma linguagem de programação amplamente reconhecida por sua aplicabilidade em ciência de dados e inteligência artificial. Na análise de séries temporais, foram empregadas técnicas para extrair padrões significativos e informações dos dados. Algumas das técnicas utilizadas neste estudo incluem:

- **Teste de Dickey-Fuller Aumentado (ADF):** A técnica de teste de raiz unitária Dickey-Fuller, frequentemente referida como o teste ADF (Dickey-Fuller aumentado), foi inicialmente desenvolvida por Robert F. Engle e Clive W.J., e posteriormente aperfeiçoada por David A. Dickey e Wayne A. Fuller em 1979. Uma técnica para verificar a estacionariedade de uma série temporal, que é um pré-requisito para muitas análises subsequentes (Said & Dickey, 1984).



- Suavização Exponencial Holt-Winter: A técnica foi desenvolvida por Charles C. Holt e Peter G. Winters em 1976 e utilizada para identificar tendências e padrões sazonais em séries temporais, permitindo previsões precisas (Hyndman & Athanasopoulos, 2018).
- Decomposição ETS: Uma técnica para separar uma série temporal em componentes de tendência, sazonalidade e resíduos, facilitando a análise individual de cada componente (Cleveland et al., 1990).

Além disso, foi realizada uma segunda decomposição somente com os grupos de ocorrências. A saber foram: ameaças, vulnerabilidades, evento adverso, registro incompleto e não se aplica.

Apesar dos resultados que podem ser derivados desta análise, é importante reconhecer algumas limitações. Primeiramente, a capacidade de generalização do estudo pode ser restrita, dado que os dados são específicos para os municípios do estado do Rio de Janeiro que participam do programa PRODEC. Além disso, a análise está sujeita às limitações inerentes às inserções errôneas de dados por parte dos municípios que podem ser motivadas por diversas razões que vão desde a falta de conhecimento, erros de digitação, erros conceituais etc. Finalmente, a qualidade dos resultados depende dos dados coletados por meio da plataforma PRODEC e podem influenciar os resultados, potencialmente introduzindo viés na análise.

4 ANÁLISE DE DADOS

Na fase inicial da análise, foi conduzida uma análise descritiva para compreender a distribuição e as características gerais dos dados. Na série temporal foi aplicado o Teste Dickey-Fuller Aumentado (ADF) para verificar a estacionariedade da série temporal (Said & Dickey, 1984).

O teste de Dickey-Fuller aumentado retornou os seguintes resultados:

Valor da estatística do teste: -4.4114; Valor-p: 0.000283; Número de *lags* utilizados : 30 (*lags* são os números de períodos anteriores a serem considerados ao modelar a dependência temporal nos dados); Número de observações usadas: 3869; Valores críticos: **1%**: -3.4320; **5%**: -2.8623; **10%**: -2.5672

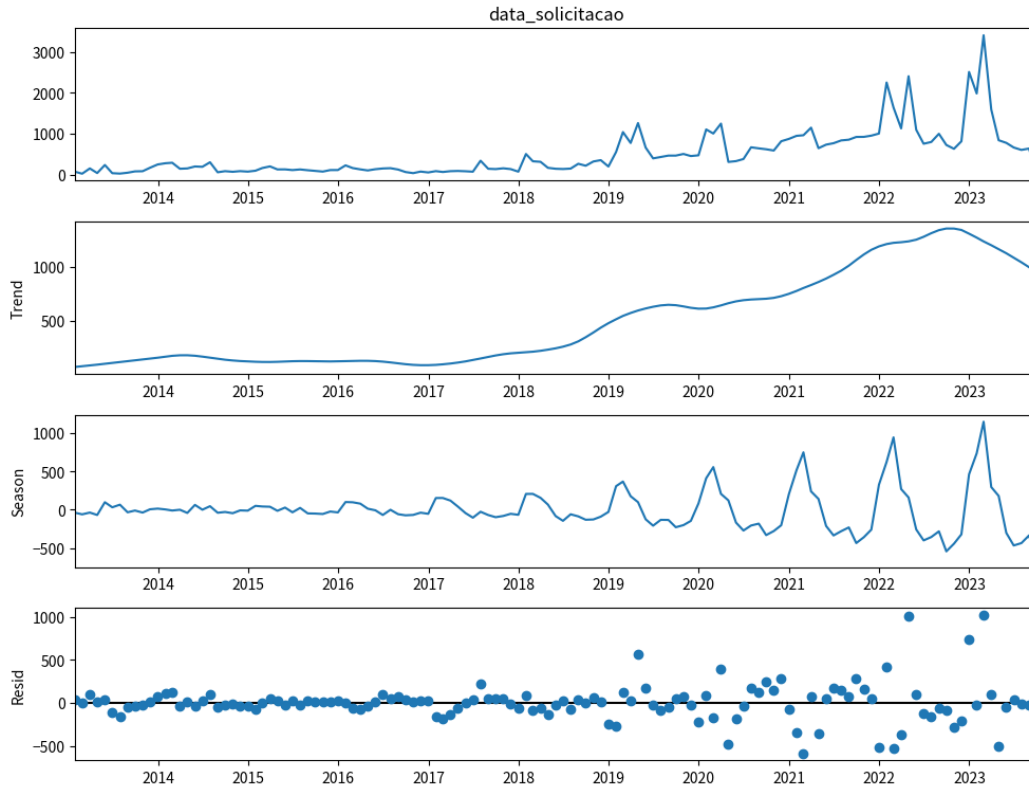
O valor-p é muito pequeno (menor que 0.01), o que nos permite rejeitar a hipótese nula de que a série temporal possui uma raiz unitária, indicando que a série é estacionária e não possui uma estrutura de série temporal aleatória.

Este teste foi crucial para determinar se a série temporal possui uma estrutura de tempo dependente, uma média e variância constantes ao longo do tempo, facilitando assim a identificação de padrões sazonais e tendências (Box et al., 2015).

A análise subsequente focou na decomposição de séries temporais para identificar e entender os componentes principais: tendência, sazonalidade e resíduos. Utilizando a técnica de decomposição ETS, foi possível isolar cada um desses componentes e analisar suas características distintas.



Figura 1 - Decomposição da Série Temporal Mensal



Fonte: O autor(2023)

A análise revelou padrões sazonais claros, com períodos de aumento de ocorrências identificados principalmente entre os meses de novembro a abril. Conforme é representado na figura 1 com quatro gráficos: a série temporal mensal, a tendência, a sazonalidade e os resíduos.

Após a decomposição, foi realizado um segundo teste de Dickey-Fuller nos resíduos para verificar se a estrutura de tempo permanece dependente ao longo do tempo, bem como a média e a variância se mantém constante, ou seja, em última análise se os dados possuem características de estacionariedade (Dickey & Fuller, 1979).

O teste de Dickey-Fuller aumentado retornou os seguintes resultados: -Valor da estatística do teste: -25.1492; Valor-p: 0.0; Número de lags utilizados: 28; Número de observações usadas: 3869; Valores críticos: **1%**: -3.4320; **5%**: -2.8622; **10%**: -2.5671

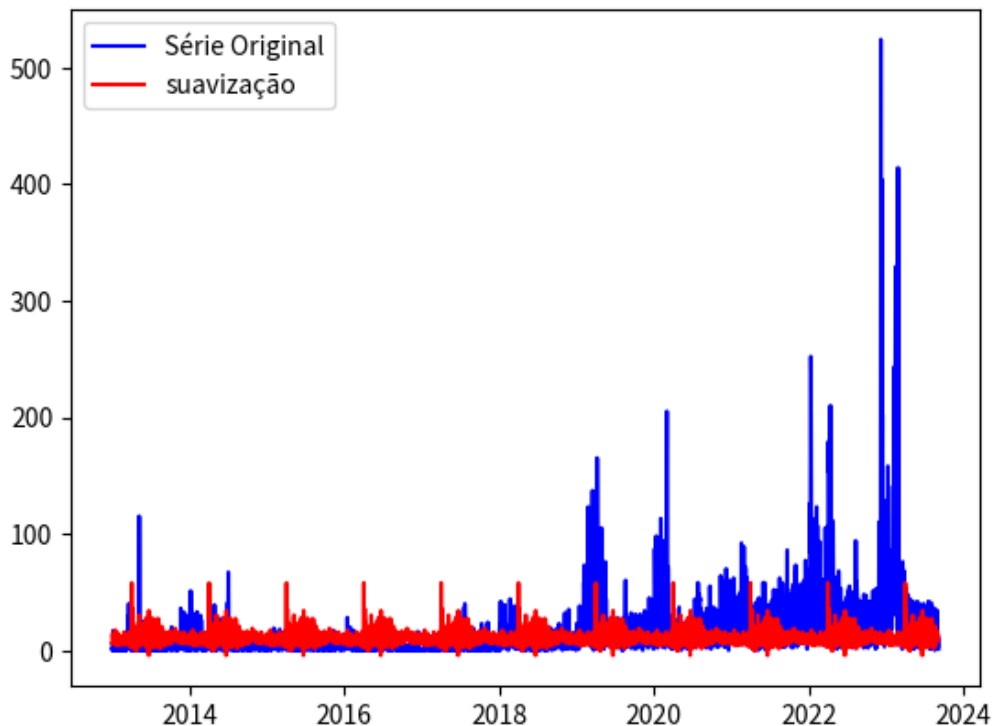
O valor-p (p-value) menor que 0,05 e a estatística de teste abaixo dos valores críticos em todos os níveis de significância (1%, 5% e 10%) indicam que os resíduos da série, após a aplicação da decomposição ETS, são estacionários.

Portanto, com base nos resultados do teste de Dickey-Fuller, pode-se afirmar que os dados da série têm representatividade na sua tendência e sazonalidade, tornando-os apropriados para possíveis emprego de processos de *machine learning* tradicionais como classificação, regressão, correlação ou associação (Hyndman, 2018).



Ao se explorar a técnica de suavização exponencial utilizando Holt-Winters, foi possível obter os resultados abaixo:

Figura 2 - técnica de suavização exponencial Holt-Winters



Fonte: O autor(2023)

Após a suavização foi realizado o teste de Dickey-Fuller nos resíduos para verificar se a tendência e a sazonalidade estão sendo captadas na série temporal. Os resultados obtidos foram os seguintes:

O teste de Dickey-Fuller aumentado retornou os seguintes resultados:

Valor da estatística do teste: -15.0756; Valor-p: $8.598...9e^{-28}$; Número de lags utilizados: 30; Número de observações usadas: 3869 ;Valores críticos:1%: -3.4320; 5%: -2.8622; 10%: -2.5671

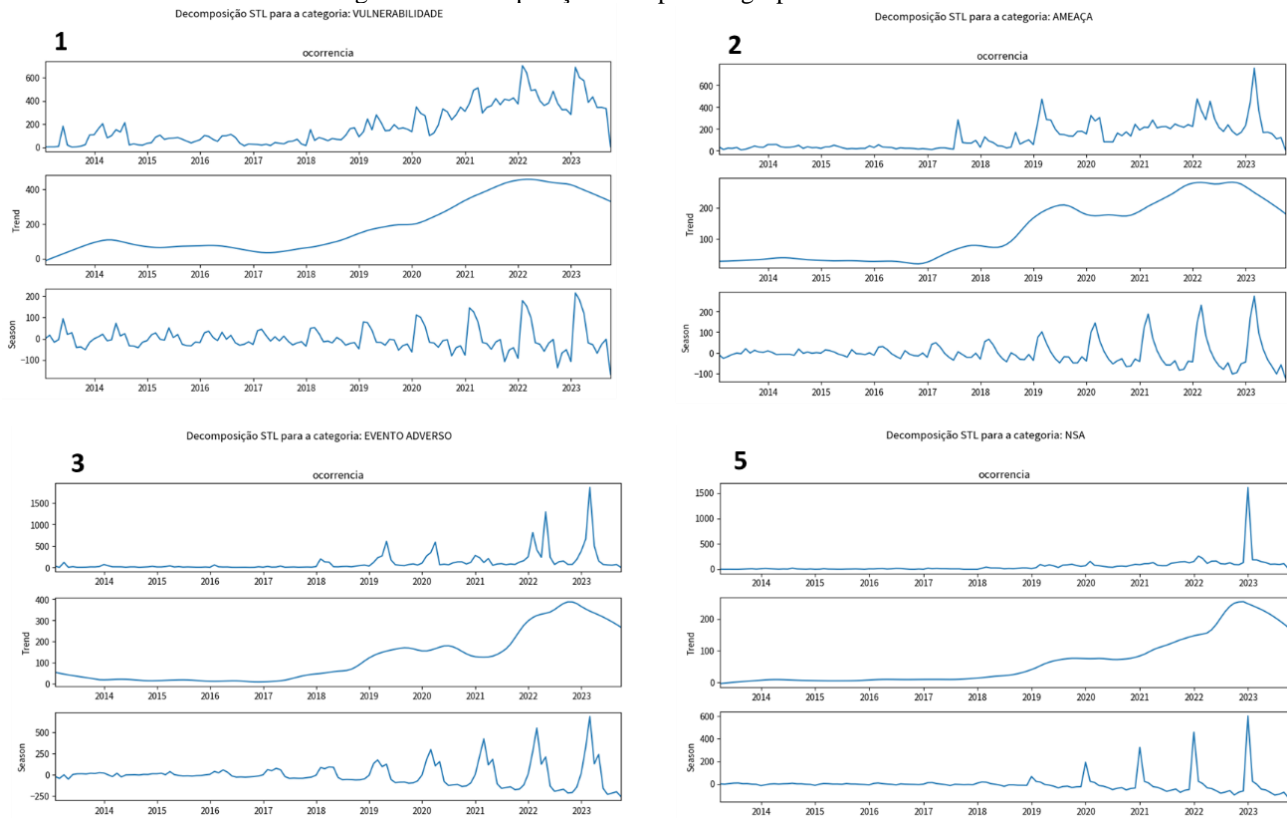
Portanto, pode-se rejeitar a hipótese nula e admitir que os dados residuais são estacionários. Dessa forma, tanto a técnica de decomposição quanto a suavização conseguiram descrever bem a tendência, sazonalidade e o resíduos com nível de significância estatística. Dessa forma, pudemos escolher entre duas técnicas distintas de séries temporais: decomposição ou suavização exponencial. Optamos por utilizar a decomposição e mencionamos a suavização, pois no futuro caso se deseje empregar técnicas de suavização é possível que esta abordagem ofereça uma melhor performance na previsão.

Na figura 3 temos o próximo tratamento de dados levando em consideração a classificação de dados por grupos de ocorrências da seguinte forma, decomposição das ocorrências vulnerabilidade (1), decomposição das ocorrências ameaça (2), decomposição das ocorrências evento adverso (3) e



decomposição das ocorrências não se aplica (5). Não foi empregado os dados dos registros incompletos.

Figura 3 - decomposição ETS para os grupos de ocorrência



Fonte: Os autores(2023)

As categorias 1, 3 e 5 mostraram padrões sazonais mais pronunciados e tendências claras, indicando que essas categorias podem ser de particular interesse para o desenvolvimento de planos de contingência eficazes. A análise também destacou a presença de componentes sazonais significativos, sugerindo que certos períodos do ano estão associados a um aumento nas ocorrências de eventos adversos que serão discutidos na próxima seção.

5 DISCUSSÃO

Os resultados obtidos através da análise de séries temporais forneceram informações importantes que facilitam a tomada de decisões baseada em evidências, um pilar crucial para a gestão eficaz de desastres. A identificação de uma clara sazonalidade, principalmente entre os meses de novembro a abril, validou a hipótese do aumento de ocorrências nos períodos do verão, previamente estabelecidas, mas também auxiliou na redução de incertezas associadas ao planejamento de contingências para os períodos de maior quantidade de ocorrências.



A exploração dos grupos de ocorrências que são classificadas como vulnerabilidade, ameaça, registros incompletos, evento adverso ou não se aplica possibilitou entender melhor como cada grupo de ocorrência contribui na série temporal por componentes (tendência, sazonalidade ou resíduos).

Essa abordagem permitiu entender a contribuição de cada grupo de ocorrência ao longo do ano, desta forma temos abaixo uma síntese da análise das componentes de cada grupo.

5.1 TENDÊNCIA

- **Vulnerabilidade:** A tendência mostra uma diminuição geral ao longo do tempo, com algumas flutuações.
- **Ameaça:** A tendência é relativamente estável, com pequenas flutuações ao longo do tempo.
- **Evento Averso:** Apresenta uma tendência crescente, indicando um aumento nas ocorrências ao longo do tempo.
- **Registro incompleto:** A tendência é bastante estável, sem mudanças significativas ao longo do tempo.
- **Não se aplica acima:** A tendência mostra uma diminuição inicial seguida de um aumento, indicando uma mudança no padrão de ocorrências ao longo do tempo.

5.2 SAZONALIDADE

- **Vulnerabilidade:** Apresenta uma sazonalidade clara, com picos e vales regulares, indicando padrões sazonais específicos.
- **Ameaça:** A sazonalidade é menos pronunciada, com flutuações menores ao longo do ano.
- **Evento Averso:** Mostra uma sazonalidade clara, com padrões de aumento e diminuição bem definidos.
- **Registro incompleto:** A sazonalidade é menos evidente, com flutuações menores ao longo do ano.
- **Não se aplica acima:** Apresenta uma sazonalidade clara, com padrões de aumento e diminuição bem definidos.

5.3 RESÍDUOS

- **Vulnerabilidade:** Os resíduos são relativamente pequenos, indicando que a maioria das variações pode ser explicada pela tendência e sazonalidade.
- **Ameaça:** Os resíduos são maiores, indicando variações que não são capturadas pela tendência e sazonalidade.
- **Evento Averso:** Os resíduos são pequenos, sugerindo que a tendência e a sazonalidade explicam a maioria das variações.



- **Registro incompleto:** Os resíduos são maiores, indicando variações significativas não capturadas pela tendência e sazonalidade.
- **Não se aplica acima:** Os resíduos são pequenos, sugerindo que a maioria das variações é explicada pela tendência e sazonalidade.

Ao examinar a tendência, observa-se que a vulnerabilidade exhibe uma diminuição geral ao longo do tempo, com algumas flutuações, porém é importante considerar que as agências responsáveis pela classificação das ocorrências podem cometer erros na categorização dos grupos, o que pode influenciar a interpretação dos resultados. Por exemplo, casos de infiltração em residências de baixa renda podem ser erroneamente classificados como eventos de ameaça, devido à complexidade da solução, levando em consideração a capacidade de resolutividade daquele grupo familiar. No entanto, esses casos têm uma forte ligação com a vulnerabilidade socioeconômica das comunidades afetadas.

Quando analisado a sazonalidade, percebe-se que a vulnerabilidade exhibe padrões sazonais claros, enquanto a ameaça apresenta flutuações menores ao longo do ano. No entanto, é importante lembrar que o conhecimento das agências de proteção e defesa civil sobre os termos e conceitos da gestão de risco de desastres pode variar, levando a diferentes interpretações. Por exemplo, eventos de possibilidade de movimentação de massa devem ser categorizados como ameaça, devido à percepção de perigo iminente, mesmo que haja uma condição subjacente de vulnerabilidade nas áreas afetadas.

Os eventos adversos apresentam uma tendência crescente, indicando um aumento nas ocorrências ao longo do tempo. Nesse caso, apesar de uma classificação mais latente devido a consumação do efeito indesejado é possível a existência de uma combinação de ameaça, vulnerabilidade e de novos eventos adversos simultaneamente, o que complica a classificação precisa ao longo de tempo. Não raro, são as agências de proteção e defesa civil que retornam ao mesmo “endereço” de atendimento devido o problema nunca ser sanado e em condições diversas, ora num contexto de vistoria para atendimento de evento adverso, ora numa ameaça ou vulnerabilidade.

Além disso, eventos de "não se aplica" ou "registro incompleto" podem representar atendimentos específicos não tipificados ou casos em andamento, refletindo a complexidade da realidade das agências de proteção e defesa civil.

6 CONCLUSÃO

A análise das séries temporais históricas de ocorrências atendidas por municípios do estado do Rio de Janeiro, utilizando a plataforma PRODEC da Secretaria Estadual de Defesa Civil, permitiu a identificação de padrões de sazonalidade e tendências, em especial o aumento de ocorrência dos meses de novembro a abril. Esses padrões sazonais e tendências foram identificados nos componentes das ocorrências.



Além disso, o estudo destacou com sucesso a importância da análise de dados na formulação de estratégias de gestão de desastres baseadas em evidências. A pesquisa forneceu informações valiosas para o desenvolvimento de planos de contingência ao identificar os meses que mais contribuem com ocorrências, por meio de uma robusta estatística inferencial, permitindo uma melhor preparação e resposta a eventos adversos.

Apesar dos desafios na classificação das ocorrências, as informações derivadas desta análise têm implicações práticas significativas para a gestão de desastres no estado do Rio de Janeiro. A identificação de padrões sazonais, mesmo com possíveis variações na classificação, permite uma melhor preparação e resposta a eventos adversos, potencialmente minimizando seu impacto nas comunidades afetadas.

Além disso, a análise baseada em dados facilita o extrapolar de resultados, oferecendo a possibilidade de previsões mais acuradas ou técnicas de investigação de causalidade entre variáveis dependentes e independentes por meio de inteligência artificial.

O presente estudo, embasado em uma análise de séries temporais, representou um avanço significativo na gestão de desastres e planejamento de contingência no estado do Rio de Janeiro.

Para o futuro, sugerimos que pesquisas adicionais se concentrem na padronização da classificação de ocorrências, na aplicação de técnicas de aprendizado de máquina para análises mais detalhadas e na adoção de inteligência artificial para previsões. Essas iniciativas têm o potencial de fortalecer ainda mais a gestão de desastres, tornando-a mais orientada por dados e eficaz na resposta a eventos adversos. Com essas direções de pesquisa, estamos confiantes de que a gestão de desastres no estado do Rio de Janeiro continuará a evoluir e aprimorar sua capacidade de proteger as comunidades em situações de risco.



REFERÊNCIAS

- Alexander, D. Resilience and disaster risk reduction: an etymological journey. *Natural Hazards and Earth System Sciences*, 16(11), 2707-2716, 2016.
- Bracewell, R. N. The Fourier Transform and Its Applications. 2^a ed. *McGraw-Hill*, 1986.
- Box, G. E. P.; Jenkins, G. M.; Reinsel, G. C.; Ljung, G. M. Time Series Analysis: Forecasting and Control. 5^a ed. *Wiley*, 2015.
- Cleveland, R. B.; Cleveland, W. S.; Mcrae, J. E.; Terpenning, I. ETS: A Seasonal-Trend Decomposition Procedure Based on Loess. *Journal of Official Statistics*, 6(1), 3-73, 1990.
- CRED. The Human Cost of Natural Disasters. *Centre for Research on the Epidemiology of Disasters*, 2015.
- Cutter, S. L. Vulnerability to environmental hazards. *Progress in Human Geography*, 20(4), 529-539, 1996.
- Perry, R. W. What Is a Disaster? In: HANDELMER, H.; TORRES, A. (Eds.), *Emergency Management: Principles and Practice for Local Government*. 2^a ed. ICMA Press, p. 1-15, 2007.
- Provost, F.; Fawcett, T. Data Science for Business: What You Need to Know about Data Mining and Data-Analytic Thinking. *O'Reilly Media, Inc.*, 2013.
- Said, S. E.; Dickey, D. A. Testing for Unit Roots in Autoregressive-Moving Average Models of Unknown Order. *Biometrika*, 71(3), 599-607, 1984.
- UNISDR. UNISDR Terminology on Disaster Risk Reduction. *United Nations International Strategy for Disaster Reduction*, 2009.
- CRED & UNISDR. Economic Losses, Poverty & Disasters 1998-2017. *Centre for Research on the Epidemiology of Disasters - CRED*, 2018.
- Hyndman, R. J., & Athanasopoulos, G. Forecasting: principles and practice. *OTexts*, 2018. Disponível em: <https://otexts.com/fpp3/>
- Shmueli, G. To explain or to predict? *Statistical Science*, 25(3), 289-310, 2010.
- Montgomery, D. C., Johnson, L. A., & Gardiner, J. S. Forecasting and Time Series Analysis. *McGraw-Hill Education*, 2012.
- Shumway, R. H., & Stoffer, D. S. Time Series Analysis and Its Applications: With R Examples. *Springer*, 2010.
- Wei, W. W. S. Time Series Analysis: Univariate and Multivariate Methods. *Pearson*, 2006.
- Chatfield, C. The Analysis of Time Series: An Introduction. *CRC Press*, 2003.
- UNISDR. Sendai Framework for Disaster Risk Reduction 2015-2030. *United Nations Office for Disaster Risk Reduction*, 2015.



Zhang, Y., Wang, Y., & Grubestic, T. H. Exploring the impact of seasonality on spatial patterns of urban residential burglary. *Journal of Criminal Justice*, 43(6), 533-543, 2015.