


RESSALVA

Atendendo solicitação do(a)
autor(a), o texto completo desta tese
será disponibilizado somente a partir
de 19/02/2025.



Universidade Estadual Paulista “Júlio de Mesquita Filho”
Instituto de Biociências – Câmpus de Botucatu
Programa de Pós-graduação em Biometria



Comparação no Desempenho dos Modelos Bayesianos Hierárquicos no Estudo da Evolução Temporal do Número de Óbitos por COVID-19 no Estado de São Paulo, 2020-2021

Juliana Aparecida Gualberto

Botucatu
2024

Juliana Aparecida Gualberto

Comparação no Desempenho dos Modelos Bayesianos Hierárquicos no Estudo da Evolução Temporal do Número de Óbitos por COVID-19 no Estado de São Paulo, 2020-2021

Tese de Doutorado apresentada ao Programa de Pós-graduação em Biometria da Universidade Estadual Paulista “Júlio de Mesquita Filho”.

Orientador: Prof. Dr. José Silvio Govone

Botucatu
2024

FICHA CATALOGRÁFICA ELABORADA PELA SEÇÃO TÉC. AQUIS. TRATAMENTO DA INFORM.
DIVISÃO TÉCNICA DE BIBLIOTECA E DOCUMENTAÇÃO - CÂMPUS DE BOTUCATU - UNESP

BIBLIOTECÁRIA RESPONSÁVEL: MARIA CAROLINA A. CRUZ E SANTOS-CRB 8/10188

Gualberto, Juliana Aparecida.

Comparação no desempenho dos modelos Bayesianos hierárquicos no estudo da evolução temporal do número de óbitos por COVID-19 no Estado de São Paulo, 2020-2021 / Juliana Aparecida Gualberto. - Botucatu, 2024

Tese (doutorado) - Universidade Estadual Paulista "Júlio de Mesquita Filho", Instituto de Biociências de Botucatu

Orientador: José Silvio Govone

Capes: 10203001

1. Análise Espaço-Temporal. 2. Autocorrelação (Estatística).
3. Espaço e tempo. 4. COVID-19 (Doença). 5. Análise Multinível.

Palavras-chave: Análises espaço-temporais; Autocorrelação; DIC;
Interação espaço-temporal; Modelos autoregressivos condicionais.

ATA DA DEFESA PÚBLICA DA TESE DE DOUTORADO DE JULIANA APARECIDA GUALBERTO, DISCENTE DO PROGRAMA DE PÓS-GRADUAÇÃO EM BIOMETRIA, DO INSTITUTO DE BIOCIÊNCIAS - CÂMPUS DE BOTUCATU.

Aos 19 dias do mês de fevereiro do ano de 2024, às 08:00 horas, no(a) Sala da Pós-graduação - IB, realizou-se a defesa de TESE DE DOUTORADO de JULIANA APARECIDA GUALBERTO, intitulada **Comparação no Desempenho dos Modelos Bayesianos Hierárquicos no Estudo da Evolução Temporal da Incidência de Mortes por COVID-19 no Estado de São Paulo, 2020-2021**. A Comissão Examinadora foi constituída pelos seguintes membros: Prof. Dr. JOSÉ SILVIO GOVONE (Orientador(a) - Participação Presencial) do(a) Departamento de Estatística Matemática Aplicada e Computação / Instituto de Geociências e Ciências Exatas (IGCE) Câmpus de Rio Claro UNESP, Prof.^a Dr.^a MIRIAM HARUMI TSUNEMI (Participação Presencial) do(a) Departamento de Biodiversidade e Bioestatística / Instituto de Biociências de Botucatu UNESP, Profa. Dra. LICIANA VAZ DE ARRUDA SILVEIRA (Participação Presencial) do(a) Departamento de Biodiversidade e Bioestatística / Instituto de Biociências de Botucatu - UNESP, Profa. Dra. GIOVANA FUMES GHANTOUS (Participação Virtual) do(a) Departamento de Ciências Básicas (ZAB) / Universidade de São Paulo Faculdade de Zootecnia e Engenharia de Alimentos Ciência e inovação da fazenda à mesa (FZEA) - USP Pirassununga, Profa. Dra. SÔNIA MARIA DE STEFANO PIEDADE (Participação Virtual) do(a) Departamento de Ciências Exatas / Escola Superior de Agricultura Luiz de Queiroz / USP. Após a exposição pela doutoranda e arguição pelos membros da Comissão Examinadora que participaram do ato, de forma presencial e/ou virtual, a discente recebeu o conceito final: Aprovada. Nada mais havendo, foi lavrada a presente ata, que após lida e aprovada, foi assinada pelo(a) Presidente(a) da Comissão Examinadora.

Prof. Dr. JOSÉ SILVIO GOVONE



Dedico este trabalho aos meus pais, que sempre acreditaram em mim e me apoiaram incondicionalmente ao longo de toda a minha jornada acadêmica. O amor, encorajamento e valores que vocês me transmitiram são a base desta conquista. Ao meu orientador, cuja orientação sábia e apoio constante foram fundamentais para o sucesso deste trabalho. Sua dedicação à excelência acadêmica e sua paixão pela pesquisa serviram como inspiração em cada etapa. E, com profunda tristeza, dedico esta tese às inúmeras vítimas da COVID-19 e às suas famílias. Que suas memórias sejam honradas, e que esta tese possa, de alguma forma, contribuir para a compreensão e enfrentamento de desafios de saúde pública como os que enfrentamos durante a pandemia.

Agradecimentos

A Deus, por ter abençoado todos os dias da minha vida, por iluminar meu caminho e me dar forças para seguir sempre em frente.

Ao Professor Doutor José Silvio Govone, que me acompanhou desde a Iniciação Científica até a conclusão do Doutorado. Sua orientação, amizade e mentoria ao longo desta jornada acadêmica foram inestimáveis. Expresso minha profunda gratidão por sua orientação e apoio, que foram fundamentais para o meu crescimento e sucesso.

Aos meus pais, Luiz e Maria, pelo apoio incondicional, torcida constante e pela confiança que depositaram em mim ao longo desta jornada.

Aos meus amigos, que se tornaram uma parte inseparável da minha vida durante a pós-graduação. Agradeço pelo apoio inabalável, incentivo, pelos momentos felizes e pela capacidade de tornar cada dia na pós-graduação uma experiência gratificante. Foi extremamente enriquecedor conhecer e conviver com cada um de vocês.

A todos os professores, funcionários e colegas do Programa de Pós-Graduação em Biometria da Universidade Estadual Paulista “Julio de Mesquita Filho” em Botucatu. Sua convivência tornou esta jornada verdadeiramente gratificante.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pelo apoio financeiro essencial que tornou este trabalho possível.

E a todas as demais pessoas que, direta ou indiretamente, contribuíram para a elaboração deste trabalho ou participaram da minha vida. Se, porventura, eu tenha me esquecido de agradecer a alguém, saibam que sua influência e apoio são profundamente valorizados e apreciados. Este trabalho não seria possível sem a contribuição de todos vocês. Muito obrigada!

*Nothing in life is to be feared, it is only to be understood. Now is the time to understand more, so
that we may fear less.*
Marie Cure

Resumo

Em dezembro de 2019, o surgimento do novo coronavírus (nCoV-2019 ou COVID-19) em Wuhan, China, desencadeou uma pandemia global que se disseminou rapidamente, afetando milhares de pessoas. A situação atingiu proporções alarmantes, levando a Organização Mundial da Saúde (OMS) a declarar, em 30 de janeiro de 2020, uma emergência de saúde pública de importância internacional, devido ao aumento exponencial de casos em todo o mundo, incluindo na China. O Brasil confirmou seu primeiro caso em 26 de fevereiro de 2020, na cidade de São Paulo, marcando o início da disseminação do vírus no país. Entre março de 2020 e dezembro de 2021, o Brasil registrou mais de 22 milhões de casos confirmados de COVID-19 e lamentáveis 600 mil mortes. No contexto da epidemiologia e análise de dados, a compreensão do comportamento da doença requer uma abordagem espaço-temporal pois permite identificar a configuração espacial da doença e sua evolução ao longo do tempo, facilitando a identificação de áreas de maior risco e embasando decisões em saúde pública. Nesse cenário, os modelos bayesianos hierárquicos têm se destacado como ferramentas valiosas para detectar aglomerados de doenças, desempenhando um papel crucial na identificação de áreas de maior risco. Além disso, a abordagem bayesiana oferece a vantagem de incorporar incertezas nos modelos e avaliar a qualidade das previsões, aspecto crucial em um contexto epidemiológico. Dada a existência de diversos modelos bayesianos hierárquicos, o objetivo deste estudo é avaliar se há um modelo superior para capturar a evolução espaço-temporal do número de óbitos decorrentes da COVID-19 no Estado de São Paulo. Para a modelagem espacial e temporal, foram empregados modelos amplamente utilizados na literatura, incluindo modelos autoregressivos condicionais (CAR) para efeitos espaciais e RW(1), RW(2) e AR(1) para efeitos temporais. Métricas como o Critério de Informação Deviance (DIC) e o Critério de Informação Watanabe-Akaike (WAIC) foram utilizadas para medir o desempenho e realizar comparações entre os modelos, sendo cruciais na avaliação da adequação dos modelos estatísticos e na determinação daqueles que oferecem as melhores previsões e *insights* para a compreensão e gestão da pandemia de COVID-19. Embora não tenha sido identificado um modelo que se destacasse dos demais, foi possível observar como os óbitos aumentaram ou diminuíram em diferentes períodos da pandemia. Este estudo evidencia a importância da análise espaço-temporal e do uso de modelos bayesianos hierárquicos na epidemiologia, contribuindo significativamente para a tomada de decisões em saúde pública e fornecendo uma ferramenta valiosa para enfrentar desafios como a pandemia de COVID-19.

Palavras-chave: Análises espaço-temporais, Autocorrelação, DIC, Interação espaço-temporal, Modelos autoregressivos condicionais, Poisson inflacionado de zero, WAIC.

Abstract

In December 2019, the emergence of the novel coronavirus (nCoV-2019 or COVID-19) in Wuhan, China, triggered a global pandemic that rapidly spread, affecting thousands of people. The situation reached alarming proportions, prompting the World Health Organization (WHO) to declare, on January 30, 2020, a public health emergency of international concern due to the exponential increase in cases worldwide, including in China. Brazil confirmed its first case on February 26, 2020, in the city of São Paulo, marking the onset of the virus's spread in the country. Between March 2020 and December 2021, Brazil recorded over 22 million confirmed cases of COVID-19 and a lamentable 600 thousand deaths. In the context of epidemiology and data analysis, understanding the disease's behavior requires a space-time approach as it allows for the identification of the spatial configuration of the disease and its evolution over time, facilitating the identification of higher-risk areas and informing public health decisions. In this scenario, hierarchical Bayesian models have stood out as valuable tools for detecting clusters of diseases, playing a crucial role in identifying higher-risk areas. Furthermore, the Bayesian approach offers the advantage of incorporating uncertainties into the models and evaluating the quality of predictions, a crucial aspect in an epidemiological context. Given the existence of various hierarchical Bayesian models, the objective of this study is to assess whether there is a superior model to capture the space-time evolution of the number of deaths due to COVID-19 in the State of São Paulo. For spatial and temporal modeling, widely used models in the literature, including conditional autoregressive (CAR) models for spatial effects and RW(1), RW(2), and AR(1) priors for temporal effects, were employed. Metrics such as the Deviance Information Criterion (DIC) and the Watanabe-Akaike Information Criterion (WAIC) were used to measure performance and make comparisons between models, being crucial in evaluating the adequacy of statistical models and determining those that offer the best predictions and insights for understanding and managing the COVID-19 pandemic. Although no model stood out from the others, it was possible to observe how deaths increased or decreased in different periods of the pandemic. This study underscores the importance of space-time analysis and the use of hierarchical Bayesian models in epidemiology, making a significant contribution to public health decision-making and providing a valuable tool to address challenges such as the COVID-19 pandemic.

Keywords: Space-time analysis, Autocorrelation, DIC, Space-time interaction, Conditional autoregressive models, Zero-inflated Poisson, WAIC.

Lista de figuras

Figura 1 – Representação simbólica do modelo de efeito principal. Os círculos denotam a independência a priori, enquanto os arredondados indicam a dependência a priori. Os pontos pequenos azuis indicam as observações no espaço-tempo (CRUZ, 2022).	29
Figura 2 – Interação do Tipo I (CRUZ, 2022).	30
Figura 3 – Interação do Tipo II (CRUZ, 2022).	31
Figura 4 – Interação do Tipo III (CRUZ, 2022).	32
Figura 5 – Interação do Tipo IV (CRUZ, 2022).	33
Figura 6 – Total de óbitos por mês por COVID-19 no período de 2020 e 2021 no Estado de São Paulo.	35
Figura 7 – Distribuição dos óbitos totais por COVID-19 no período de 2020 e 2021 nos municípios do Estado de São Paulo.	36
Figura 8 – Matriz de pesos espaciais por meio do estilo de vizinhança B (ou contiguidade <i>queen</i>) para o Estado de São Paulo.	38
Figura 9 – Matriz de pesos espaciais por meio do estilo de vizinhança M (ou contiguidade <i>rook</i>) para o Estado de São Paulo.	39
Figura 10 – Gráfico dos resíduos padronizados vs valores ajustados do modelo com a combinação de autocorrelação espacial de Besag, autocorrelação temporal RW(1) e interação tipo II	52
Figura 11 – Mapa das médias posteriori dos valores ajustados do número de óbitos por COVID-19 ao longo do tempo do modelo com a combinação de autocorrelação espacial de Besag, autocorrelação temporal RW(1) e interação tipo II. Continuação próxima página.	53
Figura 12 – Mapa das médias posteriori dos valores ajustados do número de óbitos por COVID-19 ao longo do tempo. À esquerda: modelo com autocorrelação espacial de Besag, autocorrelação temporal AR(1) com interação tipo II, covariáveis, e efeitos aleatórios não estruturados espaciais/temporais. À direita: modelo com autocorrelação espacial de Besag, autocorrelação temporal RW(1) com interação tipo II, covariáveis, e efeitos aleatórios não estruturados espaciais/temporais.	56

Lista de tabelas

Tabela 1 – Estatísticas descritivas para o número de óbitos por COVID-19 dos 645 municípios do Estado de São Paulo de 2020 e 2021.	37
Tabela 2 – Restrições de identificabilidade para os modelos espaço-temporais na Equação (2.40) (CRUZ, 2022).	47
Tabela 3 – Avaliação dos 48 modelos espaço-temporais ajustados para o número de óbitos por COVID-19 dos municípios do Estado de São Paulo de 2020 a 2021 considerando o DIC.	49
Tabela 4 – Avaliação dos 48 modelos espaço-temporais ajustados para o número de óbitos por COVID-19 dos municípios do Estado de São Paulo de 2020 a 2021 considerando o WAIC.	50
Tabela 5 – Estimativas e médias a posteriori do modelo ajustado com combinação de autocorrelação espacial de Besag, autocorrelação temporal RW(1) e interação tipo II, com intervalos de credibilidade de 95% para o número de óbitos por COVID-19 nos municípios do Estado de São Paulo de 2020 e 2021.	50

Sumário

1	INTRODUÇÃO	1
1.1	Objetivos	2
2	REVISÃO BIBLIOGRÁFICA	4
2.1	Inferência bayesiana	4
2.1.1	Modelos bayesianos hierárquicos	5
2.1.2	Família exponencial	6
2.2	Modelos lineares generalizados	7
2.2.1	Modelo regressão de Poisson	8
2.2.2	Modelos aditivamente generalizados	9
2.3	Metodologia INLA	9
2.4	Campos aleatórios gaussianos	11
2.4.1	Campos aleatórios gaussianos markovianos	13
2.5	Mapeamento espaço-temporal para dados de doenças	14
2.5.1	Dados de séries temporais	14
2.5.2	Dados espaciais	15
2.6	Modelos autoregressivos (AR)	16
2.6.1	Modelo AR(1)	16
2.6.2	Modelo RW(1)	18
2.6.3	Modelo RW(2)	19
2.7	Modelos para dados de área	20
2.8	Modelos autoregressivos condicionais (CAR)	21
2.8.1	Modelagem CAR	21
2.8.2	Modelagem ICAR	23
2.8.3	Modelagem de Leroux	24
2.9	Modelos espaço-temporais	25
2.9.1	Modelo de Bernardinelli	26
2.9.2	Modelo de interação espaço-tempo	28
3	MATERIAIS E MÉTODOS	34
3.1	Banco de dados	34
3.2	Software utilizado	34
3.3	Análise descritiva	35
3.4	Matriz de vizinhança	38
3.5	Análise da evolução espaço-temporal	39
3.6	Métodos de avaliação dos modelos	47

	4 RESULTADOS	49
4.1	Discussão	55
	5 CONCLUSÃO	57
	Referências	59
	Apêndices	65
	APÊNDICE A – PRODUTO DE KRONECKER	66
	APÊNDICE B – CÓDIGO	67

1 Introdução

No início de dezembro de 2019, um novo agente viral do coronavírus, conhecido como SARS-CoV-2 (também referido como nCoV-2019 ou COVID-19), foi identificado após o registro de casos na cidade de Wuhan, localizada na província de Hubei, China ([WORLD HEALTH ORGANIZATION, 2020a](#)). O COVID-19 é uma infecção respiratória aguda de elevada transmissibilidade, com potencial gravidade. Rapidamente, o vírus se disseminou por outras partes da China e por diversos países do mundo. Em 30 de janeiro de 2020, o Comitê de Emergência da Organização Mundial da Saúde (OMS) declarou estado de emergência de saúde global em resposta ao crescente número de casos notificados na China e em outros países ([WORLD HEALTH ORGANIZATION, 2020b](#)).

O Brasil registrou seu primeiro caso confirmado de COVID-19 em 26 de fevereiro de 2020, na cidade de São Paulo. O paciente, um homem de 61 anos e residente da capital paulista, havia recentemente viajado para a Itália ([SAÚDE, 2020](#)). Desde então, de fevereiro de 2020 até dezembro de 2021, o Brasil registrou mais de 22 milhões de casos confirmados e mais de 600 mil óbitos.

No entanto, mesmo com o elevado número de casos e óbitos confirmados de COVID-19 no Brasil, há uma grande quantidade de subnotificações, conforme apontado por [BASTOS et al. \(2019\)](#): “os atrasos na notificação, especialmente aqueles cuja estrutura varia no tempo, distorcem a relação entre a incidência da doença relatada e a verdadeira incidência da doença”. O rastreamento em tempo real de pandemias é dificultado por atrasos na notificação, que podem ser atribuídos a atrasos na confirmação laboratorial, problemas logísticos, falta de infraestrutura e testes, entre outros fatores.

Diante desse cenário, a capacidade de prever a evolução da pandemia e adotar medidas de controle eficazes se torna crucial. O mapeamento espaço-temporal se apresenta como uma ferramenta analítica valiosa para essa finalidade, permitindo a análise espacial que revela a autocorrelação entre áreas próximas e destaca regiões com maiores incidências.

Os modelos espaço-temporais frequentemente empregam conceitos como modelos autoregressivos condicionais (CAR) para fatores espaciais e modelos autoregressivos como AR(1), modelo de Random Walk, RW(1) ou RW(2) para capturar a dinâmica temporal. Esses modelos são eficazes na identificação de aglomerados de doenças e fornecem informações essenciais para

a tomada de decisões.

No entanto, a escolha adequada do modelo estatístico e a avaliação de seu desempenho são etapas cruciais na análise de dados epidemiológicos. Métricas como o Critério de Informação Deviance (DIC) ([SPIEGELHALTER et al., 2002](#)) e o Critério de Informação Watanabe-Akaike (WAIC) ([VEHTARI; GELMAN; GABRY, 2017](#)) desempenham um papel fundamental na determinação de quais modelos oferecem as previsões mais precisas e *insights* relevantes para a compreensão e gestão da pandemia de COVID-19.

Nesse contexto, a abordagem bayesiana hierárquica desempenha um papel significativo em modelos espaço-temporais, permitindo a incorporação da variabilidade entre unidades espaciais e temporais. Essa abordagem possibilita a estimativa de hiperparâmetros que modelam a heterogeneidade espacial e temporal, bem como a inclusão de covariáveis que afetam a dinâmica da doença ([MORAGA, 2019](#)).

Além de sua utilidade na detecção de aglomerados de doenças, os modelos bayesianos hierárquicos desempenham um papel crucial na identificação de áreas de maior risco e auxiliando nas tomadas de decisões em saúde pública. Além disso, a abordagem bayesiana permite a inclusão de incertezas nos modelos e a avaliação da qualidade das previsões ([GELMAN et al., 1995](#)).

Para efetuar a comparação entre os modelos propostos e avaliar sua qualidade, serão empregadas as métricas Critério de Informação Deviance (DIC) e o Critério de Informação Watanabe-Akaike (WAIC). Estas métricas proporcionam uma base sólida para a avaliação do ajuste dos modelos aos dados, considerando tanto a capacidade preditiva quanto a complexidade do modelo.

Ao alcançar esses objetivos, espera-se contribuir para uma compreensão mais profunda da evolução da pandemia no contexto estadual, ao mesmo tempo em que orientará na seleção do modelo mais adequado para descrever com precisão os padrões da pandemia.

5 Conclusão

O presente estudo teve como objetivo realizar uma comparação entre diversos modelos bayesianos hierárquicos, os quais foram empregados para investigar a evolução espaço-temporal do número de óbitos relacionados à COVID-19 no Estado de São Paulo, durante o período de 2020 e 2021. Neste trabalho, procedeu-se à adaptação de modelos bayesianos hierárquicos espaço-temporais, a fim de analisar a evolução espaço-temporal dos óbitos causados pela COVID-19 no Estado de São Paulo, no mencionado intervalo de tempo, visando à avaliação do desempenho desses modelos.

No âmbito desses modelos, incluímos a modelagem conhecida como CAR, que foi utilizada para conduzir a análise espacial dos dados relativos aos óbitos por COVID-19, os quais foram agregados em áreas ponderadas, de acordo com a divisão geográfica do estado. A escolha da modelagem CAR se fundamentou na natureza dos dados, que consistem em contagens agrupadas por unidades geográficas, e na capacidade intrínseca desses modelos de considerar a estrutura de vizinhança que existe entre essas unidades. Na análise temporal, empregamos a modelagem autoregressiva, incluindo AR(1), RW(1) e RW(2), que são os mais comumente utilizados na literatura. Contudo, a estrutura hierárquica inerente a esses modelos nos desafiou do ponto de vista computacional, desafio este que foi mitigado pela aplicação do método INLA para a inferência.

No contexto da análise estatística voltada para a investigação de doenças por meio de mapeamento, os modelos bayesianos hierárquicos têm adquirido ampla aceitação, dada sua capacidade de acomodar diferentes estruturas, incorporando efeitos aleatórios que permitem considerar informações espaciais, temporais e interações espaço-temporais. Contudo, é fundamental ressaltar que, à medida que se incorporam tais efeitos, a complexidade do modelo aumenta, o que requer uma abordagem cuidadosa no processo de desenvolvimento e implementação do modelo.

É importante observar que a escolha de um “melhor” modelo não implica que ele seja o mais apropriado para todas as situações, mas sim que auxilia na obtenção de uma compreensão robusta dos dados. A abordagem estatística empregada neste estudo constitui uma contribuição significativa para o campo da pesquisa, sendo particularmente indicada para cenários que envolvem a integração de dados provenientes de múltiplas fontes, em uma ampla escala geográfica e temporal. Essa abordagem aprimora a capacidade de realizar inferências precisas e oferece uma estrutura sólida para a análise de dados complexos.

Ao aplicar essa abordagem em outros contextos, pesquisadores e profissionais têm a oportunidade de explorar os benefícios de uma análise integrativa, incorporando informações provenientes de diversas fontes para obter uma compreensão mais abrangente e precisa dos fenômenos em estudo. Ademais, a utilização de escalas geográficas e temporais abrangentes possibilita a captura da variabilidade e das relações entre as variáveis ao longo do tempo e do espaço, contribuindo para uma melhor capacidade de inferência e tomada de decisões embasadas.

Como sugestão para trabalhos futuros, recomenda-se a realização de simulações dos modelos propostos. Essa abordagem permitirá verificar se o comportamento nos ambientes de dados controlados é congruente com as situações observadas nos dados reais. A execução de simulações proporcionará uma análise mais abrangente, possibilitando avaliar a robustez e a generalização dos modelos em diferentes contextos. Essa investigação adicional contribuirá para fortalecer a validade e a aplicabilidade dos modelos propostos em cenários práticos e fornecerá *insights* valiosos sobre seu desempenho sob condições diversas. Um exemplo da estrutura dos modelos utilizados está no Apêndice [B](#).

Referências

- AGRESTI, A. *Categorical data analysis*. [S.l.]: John Wiley & Sons, 2012. v. 792. 8
- ALLÉVIUS, B. On the precision matrix of an irregularly sampled ar(1) process. *arXiv preprint arXiv:1801.03791*, 2018. 18
- ANSELIN, L. *Spatial econometrics: methods and models*. [S.l.]: Springer Science & Business Media, 1988. v. 4. 20, 21
- ANSELIN, L. *Spatial econometrics: methods and models*. [S.l.]: Springer Science & Business Media, 1988. v. 4. 38, 39
- ATKINS, D. C. et al. A tutorial on count regression and zero-altered count models for longitudinal substance use data. *Psychology of Addictive Behaviors*, American Psychological Association, v. 27, n. 1, p. 166, 2013. 40
- BAILEY, T. C.; GATRELL, A. C. et al. *Interactive spatial data analysis*. [S.l.]: Longman Scientific & Technical Essex, 1995. v. 413. 21
- BAKSALARY, O. M.; TRENKLER, G. The moore-penrose inverse: a hundred years on a frontline of physics research. *The European Physical Journal H*, Springer, v. 46, p. 1–10, 2021. 42, 43
- BANERJEE, S.; CARLIN, B. P.; GELFAND, A. E. *Hierarchical modeling and analysis for spatial data*. [S.l.]: CRC press, 2014. 15, 24, 66
- BASTOS, L. S. et al. A modelling approach for correcting reporting delays in disease surveillance data. *Statistics in medicine*, Wiley Online Library, v. 38, n. 22, p. 4363–4377, 2019. 1
- BAYES, T. Lii. an essay towards solving a problem in the doctrine of chances. by the late rev. mr. bayes, frs communicated by mr. price, in a letter to john canton, amfr s. *Philosophical transactions of the Royal Society of London*, v. 53, p. 370–418, 1763. 4
- BERLINER, L. M. Hierarchical bayesian time series models. In: SPRINGER. *Maximum Entropy and Bayesian Methods: Santa Fe, New Mexico, USA, 1995 Proceedings of the Fifteenth International Workshop on Maximum Entropy and Bayesian Methods*. [S.l.], 1996. p. 15–22. 25
- BERNARDINELLI, L. et al. Bayesian analysis of space—time variation in disease risk. *Statistics in medicine*, Wiley Online Library, v. 14, n. 21-22, p. 2433–2443, 1995. 26, 27
- BESAG, J. Spatial interaction and the statistical analysis of lattice systems. *Journal of the Royal Statistical Society: Series B (Methodological)*, Wiley Online Library, v. 36, n. 2, p. 192–225, 1974. 2, 21, 23
- BESAG, J. Statistical analysis of non-lattice data. *Journal of the Royal Statistical Society: Series D (The Statistician)*, Wiley Online Library, v. 24, n. 3, p. 179–195, 1975. 23
- BESAG, J.; KOOPERBERG, C. On conditional and intrinsic autoregressions. *Biometrika*, Oxford University Press, v. 82, n. 4, p. 733–746, 1995. 42

- BESAG, J.; YORK, J.; MOLLIE, A. Bayesian image restoration, with two applications in spatial statistics. *Annals of the institute of statistical mathematics*, Springer, v. 43, p. 1–20, 1991. 2, 23, 41, 42
- BIASOLI, P. K. *Modelagem conjunta de média e variância em experimentos fracionados sem repetição utilizando GLM*. Dissertação (Mestrado), 2005. 7
- BLANGIARDO, M.; CAMELETTI, M. *Spatial and spatio-temporal Bayesian models with R-INLA*. [S.l.]: John Wiley & Sons, 2015. 11, 28, 43
- BOX, G. E. P. et al. *Time series analysis: forecasting and control*. [S.l.]: Princeton university press, 2015. 16, 44
- BOX, G. E. P.; TIAO, G. C. *Bayesian inference in statistical analysis*. [S.l.]: John Wiley & Sons, 2011. 66
- BROCKWELL, P. J.; DAVIS, R. A. *Introduction to time series and forecasting*. [S.l.]: Springer, 2002. 19, 45
- BROXSON, B. J. The kronecker product. UNF Digital Commons, 2006. 66
- CÂMARA, G. et al. *Anatomia de sistemas de informação geográfica-campinas: Unicamp. Instituto de Computação*, 1996. 15
- CARROLL, R. Comparing inla and openbugs for hierarchical poisson modeling in disease mapping. *Spatial and Spatio-temporal Epidemiology*, Elsevier, v. 14, p. 45–54, 2015. 55
- COWPERTWAIT, P. S. P.; METCALFE, A. V. *Introductory time series with R*. [S.l.]: Springer, 2009. 15
- CRESSIE, N.; WIKLE, C. K. *Statistics for spatio-temporal data*. [S.l.]: John Wiley & Sons, 2015. 25
- CRESSIE, N. A. C. *Statistics for spatial data*. Wiley, New York, NY, 1993. 15, 21, 23, 24
- CRUZ, R. F. Modelos espaço-temporais para mapeamento do risco de sífilis congênita e sua relação com as condições socioeconômicas e ambientais no município de são paulo de 2010 a 2016. Universidade Estadual Paulista (Unesp), 2022. ix, x, 6, 12, 16, 17, 18, 23, 24, 26, 27, 28, 29, 30, 31, 32, 33, 42, 43, 44, 46, 47
- DOBSON, A. J.; BARNETT, A. G. *An introduction to generalized linear models*. [S.l.]: CRC press, 2018. 6
- ELLIOTT, P.; WARTENBERG, D. Spatial epidemiology: current approaches and future challenges. *Environmental health perspectives*, v. 112, p. 998–1006, 2004. 14
- FIENBERG, S. E. When did bayesian inference become "bayesian". *Chance*, v. 19, n. 2, p. 49–52, 2006. 4
- FOX, J. *Applied regression, generalized linear models, and related methods*. Beverly Hills, Calif, USA: Sage Publications, 2008. 7
- GELMAN, A. et al. *Bayesian data analysis*. [S.l.]: Chapman and Hall/CRC, 1995. 2, 4, 5, 6
- GELMAN, A. et al. *Bayesian data analysis*. [S.l.]: CRC Press, 2013. 25

- GILKS, W. R.; RICHARDSON, S.; SPIEGELHALTER, D. *Markov chain Monte Carlo in practice*. [S.l.]: CRC press, 1995. 28, 30
- HAINING, R. P.; LI, G. *Regression Modelling With Spatial and Spatial-Temporal Data: A Bayesian Approach*. [S.l.]: CRC Press, 2020. 26
- HAMILTON, J. D. *Time series analysis*. [S.l.]: Princeton university press, 2020. 16, 66
- HASTIE, T. J. Generalized additive models. In: *Statistical models in S*. [S.l.]: Routledge, 2017. p. 249–307. 9
- HODGES, J. S. *Richly parameterized linear models: additive, time series, and spatial models using random effects*. [S.l.]: CRC Press, 2013. 18
- HUBIN, A.; STORVIK, G. Estimating the marginal likelihood with integrated nested laplace approximation (inla). *arXiv preprint arXiv:1611.01450*, 2016. 10
- HYNDMAN, R. J.; ATHANASOPOULOS, G. *Forecasting: principles and practice*. [S.l.]: OTexts, 2018. 14
- JALILIAN, A.; MATEU, J. A hierarchical spatio-temporal model to analyze relative risk variations of covid-19: a focus on spain, italy and germany. *Stochastic Environmental Research and Risk Assessment*, Springer, v. 35, p. 797–812, 2021. 41, 46
- JAYA, I. G. N. M.; FOLMER, H.; LUNDBERG, J. A joint bayesian spatiotemporal risk prediction model of covid-19 incidence, ic admission, and death with application to sweden. *The Annals of Regional Science*, Springer, p. 1–34, 2022. 41, 46
- KNORR-HELD, L. Bayesian modelling of inseparable space-time variation in disease risk. *Statistics in medicine*, Wiley Online Library, v. 19, n. 17-18, p. 2555–2567, 2000. 27, 28, 29, 30, 31, 33
- LAURINI, R.; THOMPSON, D. *Fundamentals of spatial information systems*. [S.l.]: Academic press, 1992. 15
- LAWSON, A. B. *Bayesian disease mapping: hierarchical modeling in spatial epidemiology*. [S.l.]: CRC press, 2018. 21, 22
- LAWSON, A. B.; BROWNE, W. J.; RODEIRO, C. L. V. *Disease mapping with WinBUGS and MLwiN*. [S.l.]: John Wiley & Sons, 2003. v. 11. 27
- LEE, D. A comparison of conditional autoregressive models used in bayesian disease mapping. *Spatial and spatio-temporal epidemiology*, Elsevier, v. 2, n. 2, p. 79–89, 2011. 44
- LEE, D.; MITCHELL, R. Boundary detection in disease mapping studies. *Biostatistics*, Oxford University Press, v. 13, n. 3, p. 415–426, 2012. 44
- LEROUX, B. G.; LEI, X.; BRESLOW, N. Estimation of disease rates in small areas: a new mixed model for spatial dependence. In: SPRINGER. *Statistical models in epidemiology, the environment, and clinical trials*. [S.l.], 2000. p. 179–191. 2, 24, 43
- LINDSEY, J. K. *Statistical analysis of stochastic processes in time*. [S.l.]: Cambridge University Press, 2004. 17

- LÓPEZ-QUILEZLEZ, A.; MUNOZ, F. Review of spatio-temporal models for disease mapping. *Final Rep. EUROHEIS*, v. 2, p. 1–19, 2009. 26
- LUTKEPOHL, H. *New introduction to multiple time series analysis*. [S.l.]: Springer Science & Business Media, 2005. 66
- MACNAB, Y. C. On gaussian markov random fields and bayesian disease mapping. *Statistical Methods in Medical Research*, SAGE Publications Sage UK: London, England, v. 20, n. 1, p. 49–68, 2011. 43
- MCCULLAGH, P. *Generalized linear models*. New York, USA: [S.l.]: Chapman Hall, 1989. 7, 8
- MORAGA, P. *Geospatial health data: Modeling and visualization with R-INLA and shiny*. [S.l.]: CRC Press, 2019. 2, 5
- MORAGA, P. et al. A geostatistical model for combined analysis of point-level and area-level data using inla and spde. *Spatial Statistics*, v. 21, p. 27–41, 2017. 10
- MYERS, R. H. *Generalized linear models: with applications in engineering and the sciences*. [S.l.]: John Wiley & Sons, 2012. 6
- NELDER, J. A.; WEDDERBURN, R. W. Generalized linear models. *Journal of the Royal Statistical Society: Series A (General)*, v. 135, p. 370–384, 1972. 7
- QGIS DEVELOPMENT TEAM. QGIS: A Comprehensive Open Source GIS. v. 24, n. 12, p. 1785–1802, 2010. 34
- QGIS DEVELOPMENT TEAM. *QGIS Geographic Information System*. Chicago, 2021. Disponível em: <<https://qgis.org/>>. 34
- R CORE TEAM. *R: A Language and Environment for Statistical Computing*. Vienna, Austria, 2021. Disponível em: <<https://www.R-project.org/>>. 9, 34
- RESENDES, A. et al. *Abordagens espaciais na Saúde Pública-Capacitação e atualização em geoprocessamento em saúde*. Brasília: Editora MS, 2006. 139 p. 15
- REZAEIAN, M. et al. The production and interpretation of disease maps: A methodological case-study. *Social psychiatry and psychiatric epidemiology*, v. 39, p. 947–954, 2004. 14
- RODRIGUES, E. C. *Inferindo a estrutura de vizinhança em modelos bayesianos espaciais*. Dissertação (Mestrado) — Universidade Federal de Minas Gerais, 2011. 24
- RUE, H. Fast sampling of gaussian markov random fields. *Journal of the Royal Statistical Society: Series B (Statistical Methodology)*, Wiley Online Library, v. 63, n. 2, p. 325–338, 2001. 18
- RUE, H.; HELD, L. *Gaussian Markov random fields: theory and applications*. [S.l.]: CRC press, 2005. 13, 18
- RUE, H. et al. R-inla: approximate bayesian inference using integrated nested laplace approximations. *Trondheim*, v. 23, p. 115, 2013. 9
- RUE, H.; MARTINO, S.; N.CHOPIN. Approximate bayesian inference for latent gaussian models by using integrated nested laplace approximations. *Journal of the royal statistical society: Series b (statistical methodology)*, v. 71, p. 319–392, 2009. 9, 10, 11, 34

- SAÚDE, M. D. Primeiro caso de coronavírus (covid-19) no brasil. Fevereiro 2020. Acessado em: 17 de maio de 2022. Disponível em: <<https://www.saude.gov.br/noticias/agencia-saude/46435-coronavirus-brasil-confirma-primeiro-caso-da-doencas>>. 1
- SAHU, S. K.; BÖHNING, D. Bayesian spatio-temporal joint disease mapping of covid-19 cases and deaths in local authorities of england. *Spatial Statistics*, Elsevier, v. 49, p. 100519, 2022. 41
- SHUMWAY, R. H.; STOFFER, D. S. *Time series analysis and its applications*. [S.l.]: Springer, 2000. v. 3. 14
- SIMÕES, T. C. *Modelagem da dinâmica espaço-temporal da abundância do Aedes aegypti, obtida com armadilhas de captura de mosquitos adultos*. Tese (Doutorado) — BVS, Rio de Janeiro, 2013. 5
- SIMPSON, D. et al. Penalising model component complexity: A principled, practical approach to constructing priors. *Statistical Science*, v. 32, n. 1, p. 1–28, 2017. 2, 43
- SPIEGELHALTER, D. J. et al. Bayesian measures of model complexity and fit. *Journal of the Royal Statistical Society Series B: Statistical Methodology*, Oxford University Press, v. 64, n. 4, p. 583–639, 2002. 2, 47
- VANEM, E.; BITNER-GREGERSEN, E. M.; WIKLE, C. K. *Bayesian hierarchical space-time models with application to significant wave height*. [S.l.]: Springer, 2013. 25
- VEHTARI, A.; GELMAN, A.; GABRY, J. Practical bayesian model evaluation using leave-one-out cross-validation and waic. *Statistics and computing*, Springer, v. 27, p. 1413–1432, 2017. 2, 48
- WADE, K. M.; QUAAS, R. L. Solutions to a system of equations involving a first-order autoregressive process. *Journal of dairy science*, v. 76, n. 10, p. 3026–3032, 1993. 18
- WAH, W.; AHERN, S.; EARNEST, A. A systematic review of bayesian spatial–temporal models on cancer incidence and mortality. *International Journal of Public Health*, Springer, v. 65, p. 673–682, 2020. 56
- WAKEFIELD, J. Disease mapping and spatial regression with count data. *Biostatistics*, Oxford University Press, v. 8, p. 158–183, 2007. 20, 38
- WALLER, L. A.; GOTWAY, C. A. *Applied spatial statistics for public health data*. [S.l.]: John Wiley & Sons, 2004. 12
- WANG, Y.; FU, L.; PAUL, S. *Analysis of Longitudinal Data with Examples*. [S.l.]: CRC Press, 2022. 17
- WEI, W. W. S. *Time series analysis*. Pearson Addison Wesley, v. 33, 2013. 19
- WICKHAM, H. *ggplot2: Elegant Graphics for Data Analysis*. [S.l.]: Springer-Verlag New York, 2016. 34
- WORLD HEALTH ORGANIZATION. Novel coronavirus (2019-ncov): Situation report, 1. jan. 2020. Acessado em: 17 de maio de 2022. Disponível em: <https://www.who.int/docs/default-source/coronaviruse/situation-reports/20200121-sitrep-1-2019-ncov.pdf?sfvrsn=20a99c10_4>. 1

WORLD HEALTH ORGANIZATION. *Statement on the second meeting of the International Health Regulations (2005) Emergency Committee regarding the outbreak of novel coronavirus (2019-nCoV)*. 2020. <[https://www.who.int/news/item/30-01-2020-statement-on-the-second-meeting-of-the-international-health-regulations-\(2005\)-emergency-committee-regarding-the-outbreak-of-novel-coronavirus-\(2019-ncov\)](https://www.who.int/news/item/30-01-2020-statement-on-the-second-meeting-of-the-international-health-regulations-(2005)-emergency-committee-regarding-the-outbreak-of-novel-coronavirus-(2019-ncov))>. Acessado em: 17 de maio de 2022. 1

Apêndices