

# Método de Bayes como base na tomada de decisão médica - uma revisão bibliográfica

## Bayes method as a basis for medical decision making - a literature review

Luciano Moura de Assunção, Francisco Bruno Teixeira, Gabriel Zaire Fonteles de Lima e Silva, Gabriela Maués de Souza, Isabela Ferreira de Freitas, Juliana Kalif dos Santos, Lucas Souza Gomes, Vinicius Queiroz Silva, Caio Vinicius Botelho Brito

### RESUMO

**Introdução:** O teorema bayesiano permite, no contexto de decisões clínicas, atualizar a probabilidade de eventos a priori, com informações para obter uma probabilidade a posteriori. Por essa razão, essa fórmula é uma ferramenta importante para lidar com as incertezas que os clínicos enfrentam na prática diária, pois é fato que na rotina assistencial a decisão médica é um processo complexo e que, para se manter atualizado, o médico muitas vezes considera os resultados de ensaios clínicos. Nesse sentido, para interpretar esses resultados adequadamente é essencial entender os métodos estatísticos envolvidos e, atualmente, um dos principais métodos de estatística inferencial é o bayesiano. **Metodologia:** Esta revisão sistemática seguiu as diretrizes PRISMA para realizar uma revisão com base na pergunta: “O método Bayes influencia na tomada de decisão médica?”. Foram incluídos estudos observacionais e experimentais que abordam o tema do estudo. As bases de dados utilizadas para a pesquisa foram: PubMed, Lilacs e Cochrane. Os termos MeSH relevantes, palavras-chave e termos livres foram adaptados de acordo com cada base de dados. **Resultados:** Foram encontrados 4.379 artigos a partir das buscas feitas com os descritores citados, desse total, 2.019 foram encontrados na plataforma LILACS e 2.360 na plataforma PUBMED. Ao aplicar os critérios de elegibilidade, foram selecionados apenas 1 da LILACS e 16 da PUBMED, totalizando 17 artigos aplicáveis à obra em questão.

**Descritores:** Teorema de Bayes; Abordagem bayesiana; Tomada de decisão clínica.

### ABSTRACT

**Introduction:** The Bayesian theorem allows, in the context of clinical decisions, to update the a priori probability of events, with information to obtain an a posteriori probability. For this reason, this formula is an important tool to deal with the uncertainties that clinicians face in daily practice, as it is a fact that in routine care, medical decisions are a complex process and that, in order to stay up to date, physicians often consider the results of clinical trials. In this sense, to interpret these results properly it is essential to understand the statistical methods involved and, currently, one of the main methods of inferential statistics is Bayesian. **Methodology:** This systematic review followed the PRISMA guidelines to conduct a review based on the question: “Does the Bayes method influence medical decision making?”. Observational and experimental studies that address the study topic were included. The databases used for the research were: PubMed, Lilacs and Cochrane. Relevant MeSH terms, keywords and free terms were adapted according to each database. **Results:** 4,379 articles were found from searches using the aforementioned descriptors, of this total, 2,019 were found on the LILACS platform and 2,360 on the PUBMED platform. When applying the eligibility criteria, only 1 from LILACS and 16 from PUBMED were selected, totaling 17 articles applicable to the work in question.

**Keywords:** Bayes' Theorem; Bayesian approach; Clinical decision making.

Universidade do Estado do Pará (UEPA).

**Data de Submissão:** 15/07/2023 - **Data de Aceite:** 29/05/2024

**Conflito de Interesse:** sem conflito de interesse.

**Fonte de auxílio à pesquisa:** recurso próprio.

**Comitê de Ética em Pesquisa:** não houve.

**Autor correspondente:** Luciano Moura de Assunção. Fundação Santa Casa de Misericórdia do Pará - Rua Bernal do Couto, 988 - Umarizal, Belém - PA, CEP 66055-080 - Telefone: (91) 99147-5287 - E-mail: l.moura.assuncao@gmail.com

## INTRODUÇÃO

A fórmula de Bayes foi descoberta há mais de 250 anos pelo inglês Thomas Bayes. No entanto, o matemático jamais tornou público nenhum resultado de seus estudos na área de probabilidade. O seu amigo, filósofo Richard Price, apresentou, em 1763 - dois anos após a morte de Bayes - um artigo do matemático que tinha a demonstração do Teorema de Bayes. O teorema permite atualizar a probabilidade a priori, com informação para obter uma probabilidade a posteriori - a probabilidade a priori diz respeito a eventos que acontecem antes de qualquer experimento; a probabilidade a posteriori consiste no resultado do refinamento de uma previsão probabilística frente às novas informações (MAIA, 2021; SIDEBOTHAM, 2020).

Dessa forma, essa ferramenta é importante para lidar com as incertezas que os clínicos enfrentam na prática diária (WEBB, SIDEBOTHAM, 2020). São várias as características que tornam o diagnóstico difícil, como exemplo, incertezas do próprio paciente, reações distintas de cada organismo, características comuns a várias moléstias, influência de medicações, novos entendimentos sobre exames e protocolos e doenças que se apresentam juntas na mesma pessoa (HRENECHEN *et al.*, 2020).

Considerando tais fatores, entende-se que na rotina de cuidados, a decisão médica é um processo complexo e nem todas as decisões podem ser tomadas a partir de modelos baseados em conhecimento, pois tais modelos podem não cobrir todos os tipos de situações (BOULET, 2019). Para interpretar resultados de ensaios clínicos adequadamente é fundamental entender os métodos estatísticos envolvidos e, atualmente, um dos principais métodos da estatística inferencial é o bayesiano (FERREIRA *et al.*, 2020).

Vale ressaltar que os sistemas de apoio à decisão clínica (programas projetados para ajudar profissionais de saúde na tomada de decisão) têm se tornado objeto de estudo durante as últimas décadas, diante do aumento da quantidade de dados, informações e conhecimento necessários para a decisão clínica (TENÓRIO *et al.*, 2011). Diante disso, este artigo tem como objetivo analisar a literatura que aborda a relação entre o teorema de Bayes e a decisão clínica, desenvolvidos no período de 2019 a 2021, a fim de verificar a aplicabilidade do teorema e as vantagens conferidas por estes estudos à prática médica.

## MÉTODOS

### Protocolo

Esta revisão sistemática seguiu as diretrizes do PRISMA (Preferência Requisitos de relatórios para revisão sistemática e meta-análise) (MOHRER *et al.*, 2009).

### Critérios de elegibilidade

Para realizar esta revisão, foi elaborada a questão: “O método de Bayes influencia na tomada de decisões médicas?”

Foram incluídos estudos observacionais e experimentais que abordavam a temática do estudo. Além disso, com o intuito de tornar a pesquisa mais atualizada, foram incluídos estudos referentes aos últimos três anos, somente encontrados em texto completo e de forma gratuita. Estudos descritivos, artigos de opinião, artigos técnicos, diretrizes, estudos em animais, estudo piloto e *in vitro* foram descartados.

### Estratégia de busca

As seguintes bases de dados foram utilizadas para as pesquisas: PubMed, Lilacs e Cochrane. Os MeSH terms, palavras-chave e termos livres relevantes foram adaptados de acordo com cada banco de dados demonstrados na tabela abaixo, sendo as buscas realizadas no dia 17/10/2021.

### Seleção de estudos

Após o término da busca, os resultados duplicados foram removidos manualmente. A seleção dos estudos foi realizada a partir do título e resumo (fase I) e, posteriormente, a partir da análise do texto completo (fase II), conforme os critérios de elegibilidade previamente estabelecidos. Além disso, as referências listadas nos estudos incluídos também foram pesquisadas manualmente para análise nos critérios de elegibilidade. As fases de seleção (I e II) dos estudos foram explicitadas nos fluxogramas a seguir, de acordo com cada base de dados escolhida.

Na base de dados Cochrane, após delimitação da frase de busca, 63 estudos foram encontrados, no entanto, após realização das fases I e II de seleção, nenhum artigo foi enquadrado para a pesquisa. Em seguida, foi feita uma filtragem sistemática e manual dos materiais de estudo, dessa vez foram escolhidos 17 artigos finais para o desenvolvimento do trabalho.

Todas as avaliações, incluindo pesquisas, seleção de estudos, avaliação de risco de viés, caracterização dos estudos e a extração de dados foram realizadas de forma independente por dois revisores e verificadas por um desacordo de terceiro avaliador.

## RESULTADOS

Foram encontrados 4.379 artigos a partir das buscas feitas com os descritores acima citados. Do total, 2.019 foram encontrados na plataforma LILACS e 2.360 na plataforma PUBMED, em que, ao realizar a aplicação dos

**Quadro 1.** Termos usados em pesquisas em bases de dados.

Base de dados	Frase de busca
PUBMED	((((((((((Bayes Theorem[MeSH Terms]) OR (Theorem, Bayes[Title/Abstract])) OR (Bayesian Forecast[Title/Abstract]) OR (Forecast, Bayesian[Title/Abstract]) OR (Bayesian Prediction[Title/Abstract]) OR (Prediction, Bayesian[Title/Abstract]) OR (Bayesian Analysis[Title/Abstract]) OR (Bayesian Approach[Title/Abstract]) OR (Approach, Bayesian[Title/Abstract]) OR (Approaches, Bayesian[Title/Abstract]) OR (Bayesian Approaches[Title/Abstract]) OR (Analysis, Bayesian[Title/Abstract]) OR (Bayesian Method[Title/Abstract]) OR (Method, Bayesian[Title/Abstract]) OR (Bayes[Title/Abstract]) OR (Bayesian inference[Title/Abstract]) AND (((((((Decision theory[MeSH Terms]) OR (Decision Theories[Title/Abstract]) OR (Theories, Decision[Title/Abstract]) OR (Theory, Decision[Title/Abstract]) OR (Decision making[MeSH Terms]) OR (Clinical Decision Making[Title/Abstract]) OR (Decision-Making, Clinical[Title/Abstract]) OR (Medical Decision-Making[Title/Abstract]) OR (Decision-Making, Medical[Title/Abstract]) OR (Medical Decision Making[Title/Abstract]))
LILACS	(mh:(Teorema de Bayes)) OR (Análise de Bayes) OR (Fórmula de Bayes) OR (Método de Bayes) OR (Predição de Bayes) OR (Previsão de Bayes) AND (mh:(Tomada de Decisão Clínica)) OR (Tomada de Decisões Clínicas) OR (Tomadas de Decisão Clínica)
COCHRANE	(Bayes Theorem) OR (Theorem, Bayes) OR (Bayesian Forecast) OR (Forecast, Bayesian) OR (Bayesian Prediction) OR (Prediction, Bayesian) OR (Bayesian Analysis) OR (Bayesian Approach) OR (Approach, Bayesian) OR (Approaches, Bayesian) OR (Bayesian Approaches) OR (Analysis, Bayesian) OR (Bayesian Method) OR (Method, Bayesian) OR (Bayes) OR (Bayesian inference) AND (Intervention Study) OR (Decision theory) OR (Decision Theories) OR (Theories, Decision) OR (Theory, Decision) OR (Decision making) OR (Clinical Decision Making) OR (Decision-Making, Clinical) OR (Medical Decision-Making) OR (Decision-Making, Medical) OR (Medical Decision Making)

Fonte: Protocolo de pesquisa, 2022.

critérios de elegibilidade, foram selecionados apenas 1 da LILACS e apenas 16 da PUBMED, totalizando 17 artigos aplicáveis para o trabalho em questão, conforme a figura 1 e a figura 2.

## DISCUSSÃO

### Raciocínio clínico, diagnóstico e tomada de decisões

O processo de tomada de decisões médicas é uma das responsabilidades intrínsecas da profissão, o compromisso e a constante busca pela melhor escolha terapêutica para cada paciente são algumas das características que acompanham o médico durante sua trajetória profissional. Segundo Wang e col. (2020), “a precisão diagnóstica de um teste ou avaliador tem um impacto crucial na tomada de decisão clínica”.

Nesse prisma, o método desenvolvido por Bayes se apresenta como um poderoso aliado nesse complexo processo que pode envolver variáveis, desde a experiência própria do profissional, até os seus conhecimentos adquiridos pelo resultado de testes estatísticos. Indubitavelmente, apoderar-se do maior número de informações disponíveis coloca esse profissional em um caminho mais seguro para o encontro do sucesso terapêutico.

O método matemático de Bayes permite que o conhecimento a priori esteja aliado ao conhecimento adquirido e, desse modo, estabeleçam probabilidades preditivas acerca do fenômeno estudado. De acordo com Webb e Sidebotham (2020), “a fórmula de Bayes

pode ajudar a interpretar os resultados de testes de doenças”. A “probabilidade prévia” é a prevalência da doença, a “informação” é a sensibilidade e especificidade do teste”. Consequentemente, inferências podem ser construídas para a interpretação de resultados de testes, de abordagens terapêuticas e, portanto, auxiliar a tomada de decisões médicas.

A medicina é tanto uma ciência quanto uma arte, o seu processo de compreensão envolve muitas variáveis que não somente o método científico, uma vez que a linguagem, as relações humanas e a habilidade de comunicação dos médicos são ferramentas presentes em seus domínios e fundamentais para a boa prática médica. Nessa lógica, todo o conhecimento a priori adquirido durante a prática de vida de médico é parte vital no exercício da profissão, constituindo um importante arsenal que pode ser utilizado amplamente em sua carreira, objetivando diagnósticos e terapias progressivamente mais precisos para os seus pacientes (CANALS, 2019).

Tentar inferir qual das abordagens é a mais correta depende não somente das queixas apresentadas por cada paciente, mas também do contexto em que são apresentadas, dado que há diferentes formas de se conduzir um atendimento de determinado agravo, considerando o cenário de diferentes níveis de atenção da saúde pública brasileira. Portanto, a tomada de uma decisão médica não é uma mera questão de manejo do paciente, envolvendo o cenário em questão e a experiência própria do médico (CANALS, 2019).

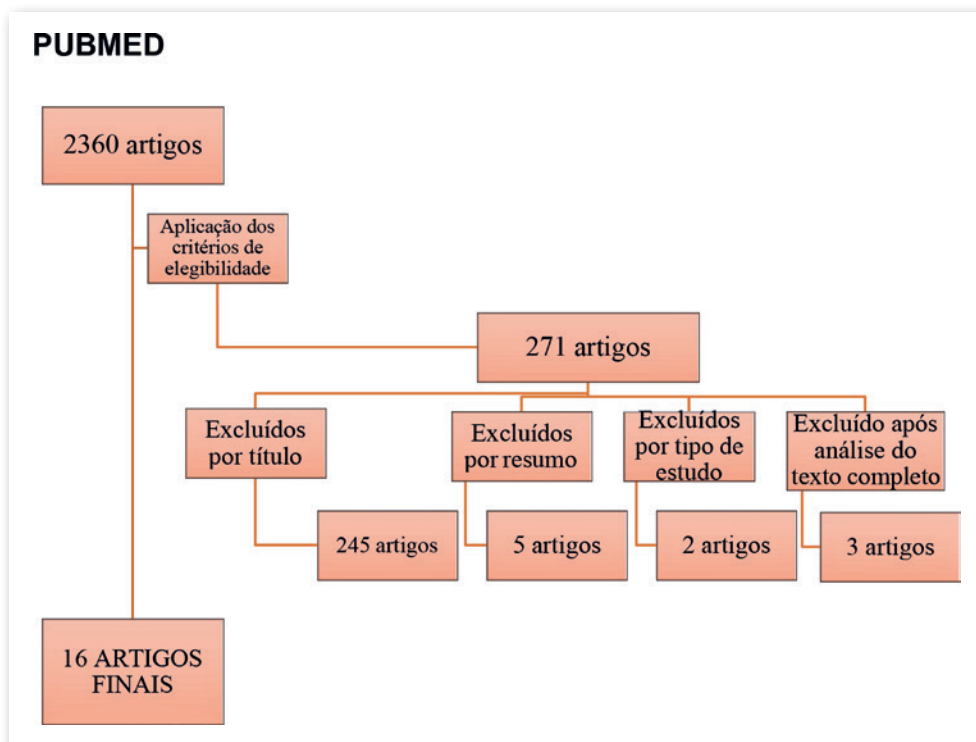


Figura 1. Legenda.  
Fonte: Os autores, 2021.

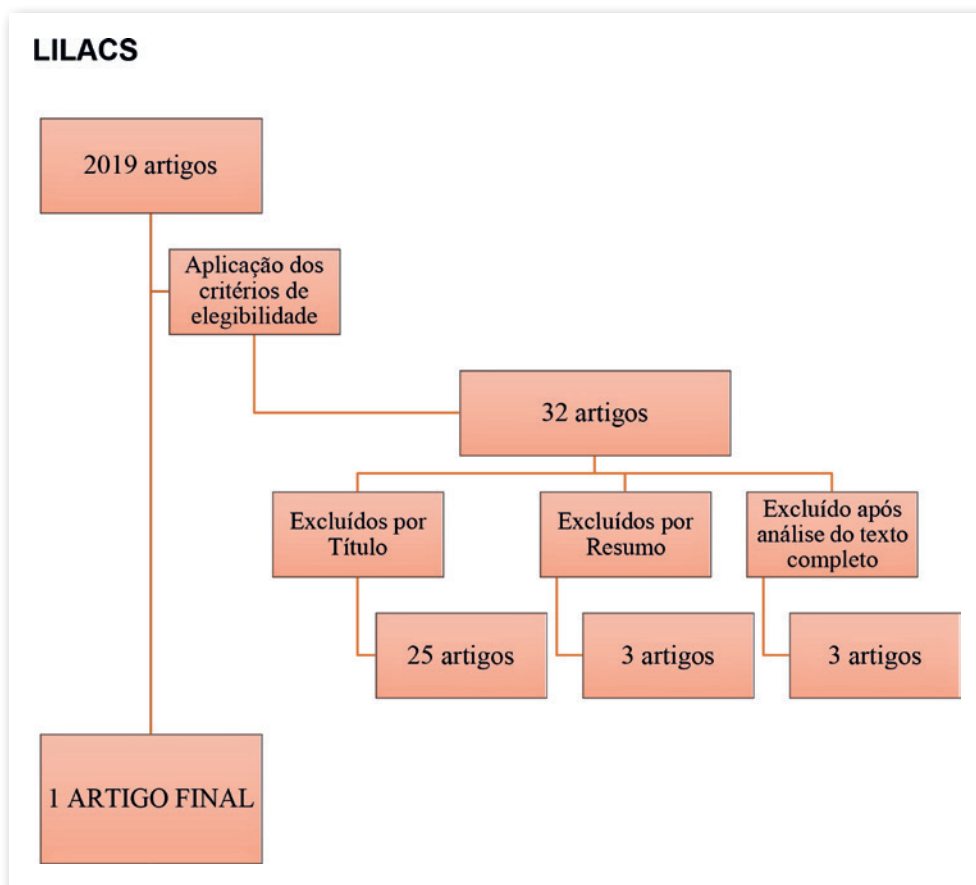


Figura 2. Legenda.  
Fonte: Os autores, 2021.

**Quadro 2.** Artigos utilizados em pesquisas em bases de dados.

Artigo	Ano	País	Título	Autor	Periódico
1	2019	Chile	Bases científicas del razonamiento clínico: inferência Bayesiana	Maurício Canais	Rev. méd. Chile
2	2020	Inglaterra	Theory and practical use of Bayesian methods in interpreting clinical trial data: a narrative review	David Ferreira, Mael Barthoulot, Julien Pottecher, Klaus D Torp, Pierre Diemunsch, Nicolas Meyer	Statistic in anestesia: a special series
3	2019	Inglaterra	Decision making and uncertainty quantification for individualized treatments using Bayesian Additive Regression Trees	Brent R Logan, Rodney Sparapani, Robert E McCulloch, Purushottam W Laud	Stat Methods Med Res.
4	2020	Inglaterra	Bayes' formula: a powerful but counterintuitive tool for medical decision-making	M.P.K. Webb e D. Sidebotham	BJA Educ.
5	2020	Inglaterra	Bayesian hierarchical Latent classmodels forestimating diagnosticaccuracy	Chunling Wang, Xiaoyan Lin, Kerrie P Nelson	Stat Methods Med Res
6	2020	Inglaterra	Integration of elicited expert information via a power prior in Bayesian variable selection: Application to colon cancer data	Sandrine Boulet, Moreno Ursino, Peter Thall, Bruno Landi, Céline Lepère, Simon Pernot, Anita Burgun, Julien Taieb, Aziz Zaanani, Sarah Zohar, Anne-Sophie Jannot	Stat Methods Med Res
7	2021	Inglaterra	Bayesian network models with decision tree analysis for management of childhood malaria in Malawi	Sanya B Taneja, Gerald PDouglas, Gregory F Cooper, Marian G Michaels, Marek J Druzzdel, Shyam Visweswaran	BMC Med Inform DecisMak.
8	2021	Holanda	Bayes' rule indiagnosis	Martijn JI Bours	J Clin Epidemiol.
9	2021	Estados Unidos da América	Patient-Specific Modeling with Personalized Decision Paths	Adriana Johnson, Gregory F Cooper, Shyam Visweswaran	AMIA Annu Symp Proc.
10	2021	Estados Unidos da América	Bayesian Framework to Augment Tumor Board Decision Making	Stefano Pasetto, Robert A Gatenby, Heiko Enderling	JCO Clin Cancer Inform.
11	2020	Inglaterra	A consensus checklist to help clinicians interpret clinical trial results analysed by Bayesian methods	David Ferreira, Mael Barthoulot, Julien Pottecher, Klaus D Torp, Pierre Diemunsch, Nicolas Meyer	Br J Anaesth
12	2020	Inglaterra	Bayesian group sequential designs for phase III emergency medicine trials: a case study using the PARAMEDIC2 trial	Elizabeth G. Ryan, Nigel Stallard, Ranjit Lall, Chen Ji, Gavin D. Perkins e Simon Gates	Trials journal
13	2020	Inglaterra	Predicting the amputation risk for patients with diabetic foot ulceration - a Bayesian decision support tool	Jens Hüsters, Guido Hafer, Jan Heggemann, Stefan Wiemeyer, Swen Malte John, Ursula Hübner	BMC Med Inform Decis Mak.
14	2020	Estados Unidos da América	Preoperative risk stratification in endometrial cancer (ENDORISK) by a Bayesian network model: A development and validation study	Reijnen C, Gogou E, Visser NCM, et al.	PLoS Med.
15	2020	Estados Unidos da América	Bayesian Data Assimilation to Support Informed Decision Making in Individualized Chemotherapy	Corinna Maier, Niklas Hartung, Jana de Wiljes, Charlotte Kloft, Wilhelm Huisinga	CPT Pharmacometrics Syst Pharmacol
16	2019	Estados Unidos da América	Long-term efficacy of different procedures for treatment of varicose veins: A network meta- analysis	Liqin Guo, Rong Huang, Dunyong Zhao, Guilian Xu, Hui Liu, Jian Yang, Tao Guo	Medicine (Baltimore).
17	2020	Inglaterra	Bayesian adaptive designs for multi-arm trials: an orthopaedic case study	Elizabeth G Ryan, Sarah E Lamb, Esther Williamson, Simon Gates	Trials journal

Fonte: Protocolo de pesquisa, 2022.

**Quadro 3.** Análises discorridas sobre os estudos evidenciados.

Artigo	Objetivos	Desenho de estudo	Resultados	Conclusão	Referência
1	Não descrito.	Análise dos autores.	A subjetividade reside apenas na distribuição de probabilidade a priori. Assim, podemos usar priori: objetivas <i>versus</i> subjetivas e informativas <i>versus</i> não informativas.	Assim, o processo diagnóstico não segue estritamente a álgebra definida na inferência bayesiana, mas coincide em sua estrutura geral, estabelecendo uma inferência indutiva quase bayesiana, que leva à proposição de uma hipótese com incerteza, a partir de uma metodologia científica.	(CANAI, 2019)
2	Comparar conceitos gerais bayesianos com métodos frequentistas para facilitar uma melhor compreensão da teoria bayesiana para leitores que não estão familiarizados com essa abordagem.	Ensaio clínico randomizado (ECR) controlado.	O método de análise bayesiano é baseado em probabilidades que, junto da análise de outros métodos estatísticos, é capaz de realizar uma análise mais complexa do estudo.	Foram comparados métodos bayesianos com métodos frequentistas usando a estrutura IMRAD para fornecer uma melhor compreensão das teorias e conceitos gerais desses dois métodos.	(FERREIRA et al., 2020)
3	Não descrito.	Revisão Simples.	Este modelo demonstrou ter um bom desempenho no ajuste de funções de regressão não paramétrica a respostas contínuas e binárias, mesmo com muitas covariáveis, além de ser computacionalmente eficiente.	O método proposto tem um desempenho muito bom em estudos extensos de simulação em comparação com vários métodos existentes.	(LOGAN, et al., 2019)
4	Discutir o conceito de probabilidade condicional explicando os princípios subjacentes à fórmula de Bayes, incluindo a ideia de probabilidade anterior e probabilidade posterior. Ilustrar o significado dos valores-P como uma probabilidade condicional que reconheça que os valores-P não significam a probabilidade de que a hipótese seja falsa.	Análise dos autores.	Foi mostrado como a fórmula de Bayes pode auxiliar na incerteza diagnóstica, como a fórmula de Bayes pode fornecer insights sobre a probabilidade de os pesquisadores realizarem conclusões erradas ao declarar que uma hipótese de estudo é verdadeira, com base em um resultado de teste estatisticamente significativo.	A fórmula de Bayes fornece uma estrutura para trabalhar com probabilidades condicionais, pode ajudar a interpretar os resultados dos testes de doenças e também pode ser usada para estimar a probabilidade de que uma hipótese de estudo seja falsa, apesar de um resultado de teste estatístico 'positivo'.	(WEBB; SIDEBOTHAM, 2020)
5	Propor dois modelos de classes latentes hierárquicas bayesianas, para permitir a estimativa da sensibilidade e especificidade de múltiplos testes diagnósticos com ou sem dados padrão-ouro.	Revisão sistemática.	Os parâmetros de modo nas distribuições beta abrangentes, portanto, refletem a sensibilidade e especificidade em nível de grupo. Outra contribuição deste artigo é fornecer algoritmos JAGS fáceis de implementar para aplicação desses modelos.	Para análise de dados reais, recomenda-se o uso de critérios de seleção de modelos, como DIC, para escolher o melhor modelo entre os diferentes modelos.	(WANG et al., 2020)
6	Comparar o desempenho do Stochastic Search Variable Selection (SSVS) baseado em potência bayesiana com o SSVS usual em nosso estudo de caso, incluindo uma análise de sensibilidade usando o parâmetro de potência anterior.	Estudo de caso.	As variáveis selecionadas diferem ao usar apenas conhecimento especializado, apenas o SSVS usual ou combinar ambos. Nosso método permite selecionar variáveis raras que podem ser perdidas usando apenas os dados observados e descartar variáveis que parecem ser relevantes com base nos dados, mas não relevantes do ponto de vista do especialista.	Método de seleção de variáveis bayesianas combina informações especializadas obtidas, dados do mundo real e seleciona um conjunto de variáveis relevantes para modelar o processo de decisão médica.	(BOULET et al., 2020)

continua...

...Continuação

**Quadro 3.** Análises discorridas sobre os estudos evidenciados.

Artigo	Objetivos	Desenho de estudo	Resultados	Conclusão	Referência
7	Descrever o conjunto de dados da avaliação de prestação de serviços do Malawi, seguido dos métodos para o desenvolvimento e avaliação de modelos de BN e da comparação de outros modelos estatísticos. Finalmente, descrever os detalhes da árvore de decisão que desenvolvem os para análise de decisão.	Ensaio clínico randomizado.	O modelo criado manualmente alcançou uma área sob a curva ROC (AUC) igual a 0,60. O modelo manual apresentou sensibilidade e especificidade de 0,74 e 0,42, respectivamente. O modelo BN automatizado, por sua vez, apresentou sensibilidade e especificidade de 0,45 e 0,68, respectivamente. Os valores de precisão balanceados foram semelhantes em todos os modelos. A análise de sensibilidade da árvore de decisão mostrou que para valores de probabilidade de malária abaixo de 0,04 e acima de 0,40, a decisão preferencial que minimiza os custos esperados é a de não realizar mRDT.	Em ambientes com recursos limitados, o uso criterioso de mRD é importante. Modelos preditivos em combinação com análise de decisão podem fornecer orientação personalizada sobre quando usar mRDT no manejo da malária infantil. Os modelos de BN podem ser derivados eficientemente de dados para apoiar a tomada de decisões clínicas.	(TANEJ A et al., 2021)
8	Não descrito.	Análise dos autores.	Se as probabilidades anteriores aumentam, o valor preditivo positivo aumenta e o valor preditivo negativo diminui. O inverso é verdadeiro para probabilidades anteriores decrescentes.	O uso da regra de Bayes no diagnóstico é relevante para entender a interação entre a probabilidade anterior de doença e as propriedades do teste diagnóstico na determinação da probabilidade posterior de doença.	(BOUR S, 2021)
9	Apresentar um novo método personalizado baseado em árvores de decisão: o Caminho de Decisão Personalizado, usando uma pontuação Bayesiana (PDP-Bay)	Análise dos autores.	O desempenho em oito conjuntos de dados sintéticos, genômicos e clínicos foi comparado ao das árvores de decisão e a um método de caminho de decisão personalizado descrito anteriormente em termos de área sob a curva ROC (AUC) e erro de calibração esperado (ECE). A complexidade do modelo foi medida pelo comprimento médio do caminho. O modelo PDP-Bay superou a árvore de decisão em termos de AUC e ECE.	Os resultados apoiam a conclusão de que a personalização pode alcançar melhor desempenho preditivo e produzir modelos mais simples do que abordagens populacionais.	(JOHNSON et al., 2021)
10	Apresentamos uma abordagem bayesiana para a previsão de tumores usando uma estrutura multimodelo para prever a resposta específica do paciente a diferentes terapias direcionadas, mesmo quando os dados históricos estão incompletos.	Análise dos autores.	Demonstramos que o poder integrativo da teoria da decisão bayesiana permite a avaliação simultânea de uma gama de opções terapêuticas.	A metodologia proposta, construída sobre uma estrutura matemática robusta e bem estabelecida, pode desempenhar um papel crucial no apoio às decisões clínicas específicas do paciente por oncologistas individuais e conselhos de tumores de várias especialidades.	(PASET TO et al., 2021)

continua...

...Continuação

**Quadro 3.** Análises discorridas sobre os estudos evidenciados.

Artigo	Objetivos	Desenho de estudo	Resultados	Conclusão	Referência
11	Nosso objetivo foi estabelecer e validar uma lista de verificação que contém um grupo de itens considerados cruciais na interpretação dos resultados de um ECR de fase III analisado com métodos bayesianos.	Revisão sistemática.	Com base em uma lista inicial de itens, três rodadas levaram a uma lista de verificação de consenso. Onze itens foram considerados informações importantes a serem especificadas para a compreensão da validade dos resultados. Destes, três foram considerados essenciais: especificação do a priori, fonte da a priori (quando a priori é informativa) e a estimativa pontual do tamanho do efeito com seu intervalo de credibilidade.	A lista de verificação pode ajudar os médicos, mesmo aqueles sem conhecimento clínico de estatística, a interpretar os resultados de um ensaio clínico randomizado de fase III, analisado por métodos bayesianos, para garantir que os principais elementos da seção estatística estejam presentes e válidos. Deve-se ter cuidado na interpretação dos resultados de um estudo analisado por métodos bayesianos que não são relatados com esses três itens essenciais, pois a validade dos resultados não pode ser estabelecida.	(FERREIRA et al., 2020)
12	O objetivo deste trabalho é explorar como projetos sequenciais de grupos bayesianos poderiam ser construídos para ensaios de fase III conduzidos em medicina de emergência.	Estudo controlado randomizado de fase III.	Produzimos três designs sequenciais alternativos do grupo bayesiano, cada um com poder superior a 90% para detectar o efeito do tratamento alvo. Um desenho bayesiano que realizou análises provisórias a cada 500 pacientes recrutados produziu o menor tamanho médio de amostra. Usando os desenhos alternativos, o estudo PARAMEDIC2 poderia ter declarado adrenalina superior para sobrevivência de 30 dias com aproximadamente 1.500 pacientes a menos.	Usando o PARAMEDIC2 como estudo de caso, demonstramos como projetos sequenciais de grupos bayesianos podem ser construídos para estudos de medicina de emergência de fase III. A estrutura bayesiana nos permitiu obter projetos eficientes usando critérios de decisão baseados na probabilidade de benefício ou dano. Junto a isso, nos permitiu incorporar informações de estudos anteriores sobre o efeito do tratamento por meio das distribuições anteriores. Recomendamos o uso mais amplo de abordagens bayesianas em ensaios clínicos de fase III.	(RYAN et al., 2020)
13	Projetar modelos de previsão bayesianos, pois produzem regras de decisão transparentes, quantificam a incerteza de forma intuitiva e reconhecem o conhecimento científico prévio disponível.	Análise dos autores por Regressão Logística.	Este estudo incluiu 237 pacientes. A média de idade foi de 65,9 (DP 12,3), desses, 83,5% eram do sexo masculino. Quanto ao desfecho, 31,6% foram submetidos a qualquer procedimento e 12,2% a procedimento de amputação maior. Os fatores de risco de perfusão, extensão e profundidade da úlcera revelaram impacto nos desfechos, enquanto o estado de infecção e a sensação não revelaram. O modelo de amputação maior usando informações anteriores superou a contraparte não informada (AUC 0,765 vs AUC 0,790, d de Cohen's 2,21). Em contraste, os modelos que prevêem qualquer amputação tiveram desempenho semelhante (0,793 vs 0,790, d de Cohen 0,22).	Ambos os modelos de risco de amputação bayesiana apresentaram valores prognósticos aceitáveis, o modelo de amputação maior se beneficiou da incorporação de informações a priori de um estudo anterior. Assim, a classificação PEDIS serve como base válida para uma ferramenta de apoio à decisão clínica para a previsão do risco de amputação em pacientes com úlcera do pé diabético. Além disso, demonstramos o uso da informação científica prévia disponível dentro de uma estrutura bayesiana para estabelecer cadeias de conhecimento.	(HUSERS et al., 2020)

continua...



...Continuação

**Quadro 3.** Análises discorridas sobre os estudos evidenciados.

Artigo	Objetivos	Desenho de estudo	Resultados	Conclusão	Referência
14	Preoperative risk stratification in endometrial cancer (ENDORISK) by a Bayesian network model: A development and validation study.	Estudo de coorte multicêntrico retrospectivo.	Uma rede bayesiana denominada ENDORISK (estratificação de risco pré-operatório em câncer endometrial) foi desenvolvida incluindo os seguintes preditores: grau pré-operatório do tumor; expressão imuno-histoquímica de receptor de estrogênio (ER), receptor de progesterona (PR), p53 e molécula de adesão celular L1 (L1CAM); nível sérico do antígeno de câncer 125; contagem de trombócitos; resultados de imagem sobre linfadenopatia; e citologia cervical. Na coorte MoMaTEC, a área sob a curva (AUC) foi de 0,82 (intervalo de confiança [IC] de 95% 0,76-0,88) para LNM e 0,82 (IC 95% 0,77-0,87) para DSS de 5 anos. Na coorte PIPENDO, a AUC para o DSS de 5 anos foi de 0,84 (IC 95% 0,78-0,90). A rede estava bem calibrada. Na coorte MoMaTEC, 249 pacientes (55,8%) foram classificados com risco <5% de LNM, com uma taxa de falsos negativos de 1,6%.	Neste estudo, ilustramos como as redes bayesianas podem ser usadas para individualizar a tomada de decisão clínica em oncologia, incorporando biomarcadores multimodais e de fácil acesso. A rede mostra as interações complexas subjacentes ao processo carcinogênico do câncer de endométrio por sua representação gráfica. Um estudo prospectivo de viabilidade será necessário antes da implementação na clínica.	(REIJNEN et al., 2020)
15	Comparar métodos de assimilação de dados bayesianos com abordagens baseadas em estimativa máxima a posteriori. Ainda, mostrar como as declarações probabilísticas sobre os principais marcadores relacionados à neutropenia induzida pela quimioterapia podem ser aproveitadas para um suporte mais informativo à decisão na quimioterapia individualizada.	Análise dos autores.	Assimilação de dados bayesiana Bayesiana Sequencial provou ser mais eficiente computacionalmente para lidar com a variabilidade entre ocasiões e integrar dados de monitoramento de medicamentos terapêuticos/biomarcadores.	Para novos dispositivos de monitoramento digital que permitem coleta de dados mais frequente, esses recursos serão de importância crítica para melhorar as decisões de atendimento ao paciente em diversas áreas terapêuticas.	(MAIER et al., 2020)

continua...

...Continuação

**Quadro 3.** Análises discorridas sobre os estudos evidenciados.

Artigo	Objetivos	Desenho de estudo	Resultados	Conclusão	Referência
16	O objetivo deste estudo é investigar a eficácia a longo prazo de diferentes procedimentos baseados na metanálise da rede bayesiana e classificar as opções terapêuticas para a tomada de decisão clínica.	Revisão sistemática.	Um total de 39 ECRs abrangendo um total de 6.917 membros foram elegíveis e forneceram dados brutos relativos. Após análise quantitativa, o procedimento CHIVA foi determinado como tendo a melhor eficácia a longo prazo, pois apresentou a maior taxa de tratamento bem sucedido (SUCRA, 0,37). Além disso, os resultados revelaram que a CHIVA possui a maior probabilidade de atingir a menor taxa de recorrência de longo prazo (SUCRA, 0,61). Ademais, a análise de sensibilidade com abordagem de inconsistência esclareceu a confiabilidade dos principais resultados e a evidência da maioria das comparações diretas foi classificada como alta ou moderada.	CHIVA pareceu ter benefícios clínicos superiores na eficácia a longo prazo no tratamento de varizes. Contudo, a conclusão ainda precisa de ensaios adicionais para apoiar as evidências.	(GUO et al., 2019)
17	O objetivo deste trabalho é demonstrar como projetos adaptativos bayesianos podem ser construídos para ensaios clínicos de fase III de vários braços e avaliar os potenciais benefícios que esses projetos oferecem.	Estudo controlado randomizado.	Construímos cinco desenhos adaptativos bayesianos, cada um com alto poder e recrutando menos pacientes em média do que o tamanho da amostra alvo dos desenhos originais. As execuções virtuais mostraram que a maioria dos desenhos bayesianos teria levado a julgamentos que declaravam superioridade de uma das intervenções sobre o controle. Projetos adaptativos bayesianos com RAR ou queda de braço foram mais propensos a alocar pacientes para braços com melhor desempenho em cada análise intermediária. Estimativas e conclusões semelhantes foram obtidas dos desenhos adaptativos bayesianos a partir do estudo original.	Usando o Collaborative Ankle Support Trial como exemplo, este estudo de caso mostra como projetos adaptativos bayesianos podem ser construídos para ensaios multibraços de fase III usando critérios de decisão clinicamente relevantes. Esses projetos demonstraram que podem gerar resultados mais precoces e alocar mais pacientes para braços com melhor desempenho. Recomendamos o uso mais amplo de abordagens adaptativas bayesianas em ensaios clínicos de fase III.	(RYAN et al., 2020)

Fonte: Protocolo de pesquisa, 2022.

Ao mesmo tempo, o passo a passo do método científico está intrinsecamente agregado à prática clínica e à tentativa do combate a uma enfermidade, pois é necessário levar em consideração diversos fatores, como o conhecimento do problema, o surgimento de uma hipótese diagnóstica e as diversas formas de se acumular conhecimento. Ainda, considera-se também os conhecimentos exigidos para testar as hipóteses, seja na forma de uma anamnese completa bem realizada, na solicitação de exames de imagem e laboratoriais ou na execução de um bom exame físico.

Nessa lógica, os autores Webb e Sidebotham (2020) atestam que “Bayes fornece uma estrutura para trabalhar com probabilidades condicionais. Começando

com uma probabilidade prévia, a fórmula de Bayes nos permite atualizar a anterior com “informações” para obter uma probabilidade posterior”. Portanto, há um importante paralelo com o processo de inferência bayesiana, visto que um médico deve apoderar-se dos conhecimentos a priori de uma determinada patologia e de sua epidemiologia, bem como da realidade do ambiente em que se encontra o paciente.

### Modelos matemáticos computadorizados e ferramentas digitais bayesianas

A medicina moderna dispõe de ferramentas computadorizadas, baseadas em modelos matemáticas, com destaque aos bayesianos, os quais se originam da

fórmula probabilística  $P(A|B) = P(B|A) \times P(A)/P(B)$ , que permitem significativos avanços aos  $P(B)$  processos de diagnóstico e de tomada de decisões. Tal avanço demonstra a eficiência em aliar o conhecimento do profissional àquilo que pode ser previsto com bases probabilísticas, assim como Bayes propôs ainda no século XVIII, sem ter a dimensão dos avanços científicos computadorizados atuais (REIJNEN *et al.*, 2020).

Nesse contexto, na medida em que guias para o planejamento de tratamentos ganham força no atual cenário da medicina, redes bayesianas possuem grande aplicabilidade em ferramentas digitais de auxílio diagnóstico, tais como modelos computacionais de aprendizado automatizados, capazes de fomentar a associação entre importantes variáveis epidemiológicas, sintomatológicas e causais. Desse modo, a progressão de uma dada patologia pode ser elucidada no intuito de auxiliar o entendimento médico, de uma maneira bem próxima ao raciocínio clínico de um profissional da área da saúde. De certo, essa evolução tecnológica é uma poderosa arma no processo de tomada de decisões médicas (REIJNEN *et al.*, 2020).

O uso dessas ferramentas é importante na medida em que pode evitar a realização de medidas terapêuticas desnecessárias no manejo, por exemplo, de pacientes graves. Além disso, permite a estratificação de risco de cada paciente, baseando-se em suas particularidades, contribuindo para a economia de tempo e de recursos, algo imprescindível para a lógica moderna da medicina personalizada. Somado a isso, há possibilidade de redução do sofrimento dos pacientes, respeitando sempre a perspectiva do modelo biopsicossocial de cuidado, progressivamente, ao cobrir cada história de forma completa, humana e individualizada (REIJNEN *et al.*, 2020).

Cada indivíduo responde de maneira particular a um tratamento, essa heterogeneidade é uma justificativa para o uso de modelos matemáticos que visem auxiliar o médico para que possa adaptar diferentes estratégias de modo a otimizar suas decisões, mas de maneira individualizada para cada paciente. Nessa lógica, os modelos bayesianos mais uma vez mostram-se em consonância com os pilares da medicina, tendo em vista que há precisão na identificação dos melhores tratamentos e proporciona melhores tomadas de decisão, que são cruciais na profissão.

Tal personalização de tratamento pode ser sistematizada baseando-se em características do caso clínico de um paciente, como em aspectos genéticos. Desse modo, aquilo que era a personalização de um tratamento específico pode ser formalizado como uma decisão médica e passa a ser uma regra de tratamento.

Portanto, os modelos bayesianos possibilitam variadas, complexas e, por vezes, revolucionárias perspectivas de análise (GUO *et al.*, 2019; LOGAN *et al.*, 2017; MAIER *et al.*, 2020).

### Exemplos bem sucedidos do modelo bayesiano na tomada de decisões

Em diversas regiões do mundo em que há falta de recursos, instalações de cuidado à saúde e de profissionais clínicos, o uso de modelos de predição probabilístico baseados em características de uma doença pode ser vital para o adequado tratamento de pacientes e para o aumento das suas chances de recuperação. Nesses cenários, a exemplo do tratamento de crianças com malária em Malawi, na África, o uso desses modelos bayesianos mostrou-se eficaz e rápido para os profissionais no momento das suas tomadas de decisões, dado que ofertam orientação personalizada e dados de suporte primordiais para os médicos, sobretudo, em ambientes com ausência de recursos. Ratifica-se, então, a importância do método na tomada de decisões, pois profissionais podem apoderar-se de modelos de predição probabilística, baseada em análise bayesiana, obtendo resultados positivos, como percebe-se em ambientes com recursos limitados em que a tomada de decisões clínicas de maneira rápida e eficiente é primordial para o tratamento dos pacientes (TANEJA *et al.*, 2021).

Outro exemplo de sucesso em que o método auxilia é na pesquisa e no tratamento oncológico. Apesar da principal problemática enfrentada não ser relacionada à falta de recursos, os profissionais da área lidam com excruciantes desafios, como a recorrente falta de dados completos dos pacientes, ou a falta de acesso dos oncologistas a um quadro de tumores.

Nessa conjuntura, mais uma vez, o uso do modelo bayesiano é uma ferramenta estratégica na medida em que pode ser usado enquanto um modelo matemático que permite prever a resposta de um paciente a diferentes tipos de terapia, resultando em uma gama de opções terapêuticas que apoiam o processo de tomada de decisão dos profissionais para diversos pacientes, respeitando suas individualidades e as especificidades de cada diagnóstico. De certo, a combinação entre o rigor e a flexibilidade matemática que acompanham a teoria bayesiana possui uma crucial contribuição no apoio dessas decisões (PASETTO *et al.*, 2021).

### CONSIDERAÇÕES FINAIS

Indubitavelmente, a inferência bayesiana não define uma taxa de sucesso absoluto em todas as formas de se

chegar a um diagnóstico diferencial, uma vez que cada situação é passível de variáveis próprias que divergem de paciente para paciente. Entretanto, sem dúvidas, o conjunto formado pelo conhecimento dos médicos acerca das patologias em suas determinadas áreas de especialização, aliado à experiência profissional, permite uma maior precisão nas hipóteses diagnósticas, com uma menor taxa de erro provável e, assim, uma maior possibilidade de tratamento com sucesso dos pacientes.

Permitir aos profissionais e aos pesquisadores que utilizem de experiências passadas, conhecimentos fisiológicos, observações de casos similares e, ainda, de opiniões de outros especialistas de uma determinada área, colocam o raciocínio bayesiano muito próximo daquele exercido naturalmente pelos profissionais da saúde em suas buscas por diagnósticos clínicos. Busca essa que envolve a probabilidade dos pacientes apresentarem uma dada patologia de acordo com os conhecimentos que esses profissionais possuem previamente sobre a epidemiologia de um agravo, os seus fatores de risco e a frequência dos sintomas, para que então, após munidos dos resultados de exames e de testes sejam capazes de uma conclusão diagnóstica tão precisa quanto possível.

Logo, Bayes, em sua obra, oferta uma gama de possibilidades, as quais são plenamente aplicáveis na investigação diagnóstica de qualidade, pois visam assegurar os tratamentos feitos em moldes de plausibilidade, seja de origem do próprio profissional de saúde através do contato prévio, seja por meio das ferramentas digitais que auxiliam na busca pelo melhor diagnóstico.

## REFERÊNCIAS

- BOULET, S. et al. Integration of elicited expert information via a power prior in Bayesian variable selection: Application to colon cancer data. *Statistical Methods in Medical Research*, v. 29, n. 2, p. 541-567, 1 fev. 2020. (<https://pubmed.ncbi.nlm.nih.gov/30963815/>)
- CANALS L., M. Bases científicas del razonamiento clínico: inferencia Bayesiana. *Revista médica de Chile*, v. 147, n. 2, p. 231-237, fev. 2019. ([https://www.scielo.cl/scielo.php?script=sci\\_arttext&pid=S0034-98872019000200231](https://www.scielo.cl/scielo.php?script=sci_arttext&pid=S0034-98872019000200231))
- FERREIRA, D. et al. A consensus checklist to help clinicians interpret clinical trial results analysed by Bayesian methods. *British Journal of Anaesthesia*, v. 125, n. 2, p. 208-215, ago. 2020. (<https://pubmed.ncbi.nlm.nih.gov/32571570/>)
- FERREIRA, D. et al. Theory and practical use of Bayesian methods in interpreting clinical trial data: a narrative review. *British Journal of Anaesthesia*, v. 125, n. 2, p. 201-207, 2020.
- GUO, L. et al. Long-term efficacy of different procedures for treatment of varicose veins. *Medicine*, v. 98, n. 7, p. e14495, fev. 2019. (<https://www.ncbi.nlm.nih.gov/pmc/articles/PMC6408126/>)
- HRENECHEN, J. W.; BORGES, A. P.; KOSCIANSKI, A. Computação na medicina: a técnica de raciocínio baseado em casos temporais no auxílio ao diagnóstico. *Brazilian Journal of Development*, v. 6, n. 10, p. 77608-77615, 2020.
- HU, D. et al. How to Conduct a Bayesian Network Meta-Analysis. *Frontiers in Veterinary Science*, v. 7, 19 maio 2020. (<https://pubmed.ncbi.nlm.nih.gov/32509807/>)
- HÜSERS, J. et al. Predicting the amputation risk for patients with diabetic foot ulceration - a Bayesian decision support tool. *BMC Medical Informatics and Decision Making*, v. 20, n. 1, 24 ago. 2020. (<https://bmcmmedinformdecismak.biomedcentral.com/articles/10.1186/s12911-020-01195-x>)
- JOHNSON, A.; COOPER, G. F.; VISWESWARAN, S. Patient-Specific Modeling with Personalized Decision Paths. *AMIA... Annual Symposium proceedings. AMIA Symposium*, v. 2020, p. 602-611, 2021. (<https://www.ncbi.nlm.nih.gov/pmc/articles/PMC8075540/>)
- LOGAN, B. R. et al. Decision making and uncertainty quantification for individualized treatments using Bayesian Additive Regression Trees. *Statistical Methods in Medical Research*, v. 28, n. 4, p. 1079-1093, 18 dez. 2017. (<https://pubmed.ncbi.nlm.nih.gov/29254443/>)
- MAIA, R. S. O Teorema de Bayes: aplicações atuais. Orientador: Prof. Dr. Marcelo Gomes Pereira. 2021. Dissertação (mestrado) - Matemática em rede nacional, departamento de matemática mestrado profissional, universidade federal do Rio Grande do Norte, Natal, 2021.
- MAIER, C. et al. Bayesian Data Assimilation to Support Informed Decision Making in Individualized Chemotherapy. *CPT: pharmacometrics & systems pharmacology*, v. 9, n. 3, p. 153-164, 1 mar. 2020. (<https://pubmed.ncbi.nlm.nih.gov/31905420/>)
- MOHER, D. et al. Preferred Reporting Items for Systematic Reviews and Meta-Analyses: the PRISMA Statement. *PLoS Medicine*, v. 6, n. 7, 21 jul. 2009. (<https://pubmed.ncbi.nlm.nih.gov/19621072/>)
- PASETTO, S.; GATENBY, R. A.; ENDERLING, H. Bayesian Framework to Augment Tumor Board Decision Making. *JCO Clinical Cancer Informatics*, n. 5, p. 508-517, maio 2021. (<https://pubmed.ncbi.nlm.nih.gov/33974446/>)
- REIJNEN, C. et al. Preoperative risk stratification in endometrial cancer (ENDORISK) by a Bayesian network model: A development and validation study. *PLoS medicine*, v. 17, n. 5, p. e1003111, 1 maio 2020. (<https://pubmed.ncbi.nlm.nih.gov/32413043/>)
- RYAN, E. G. et al. Bayesian adaptive designs for multi-arm trials: an orthopaedic case study. *Trials*, v. 21, n. 1, 14 jan. 2020. (<https://pubmed.ncbi.nlm.nih.gov/31937341/>)
- RYAN, E. G. et al. Bayesian group sequential designs for phase III emergency medicine trials: a case study using the PARAMEDIC2 trial. *Trials*, v. 21, n. 1, 14 jan. 2020. (<https://trialsjournal.biomedcentral.com/articles/10.1186/s13063-019-4024-x>)
- SIDEBOTHAM, D. Are most randomised trials in anaesthesia and critical care wrong? An analysis using Bayes' theorem. *Anaesthesia*, 2020.
- TANEJA, S. B. et al. Bayesian network models with decision tree analysis for management of childhood malaria in Malawi. *BMC Medical Informatics and Decision Making*, v. 21, n. 1, 17 maio 2021. (<https://bmcmmedinformdecismak.biomedcentral.com/articles/10.1186/s12911-021-01514-w>)
- TENÓRIO, J. M. et al. Experiências internacionais da aplicação de sistemas de apoio à decisão clínica em gastroenterologia. *Journal of Health Informatics*, v. 3, n. 1, p. 27 - 31, 2011.
- WANG, C.; LIN, X.; NELSON, K. P. Bayesian hierarchical latent class models for estimating diagnostic accuracy. *Statistical Methods in Medical Research*, v. 29, n. 4, p. 1112-1128, 30 maio 2019. (<https://pubmed.ncbi.nlm.nih.gov/31146651/>)
- WEBB, M. P. K.; SIDEBOTHAM, D. Bayes' formula: a powerful but counterintuitive tool for medical decision-making. *BJA Education*, v. 20, n. 6, p. 208-213, jun. 2020. (<https://www.ncbi.nlm.nih.gov/pmc/articles/PMC7808025/>)