


INFERÊNCIA BAYESIANA COMO FERRAMENTA PARA REDUÇÃO DE INCERTEZAS DIAGNÓSTICAS EM CÂNCER

 <https://doi.org/10.63330/aurumpub.044-015>

Victor Hugo Moreira de Lima

Doutorando em Saúde Coletiva
Universidade Estadual do Ceará - UECE, Fortaleza CE
E-mail: victor.hg.ml@hotmail.com
Lattes: <https://lattes.cnpq.br/6259720330130203>
ORCID: <https://orcid.org/0000-0003-2601-768X>

Diogo Henrique Juliano Pinto de Moura

Graduando em Medicina
Faculdade Serra Dourada - SERRA DOURADA, São Paulo, SP
E-mail: diogohjmoura@gmail.com
Lattes: <https://lattes.cnpq.br/6267523224276372>
ORCID: <https://orcid.org/0009-0007-2841-4298>

Íris Eccard Camara

Graduanda em Medicina
Faculdade de Medicina de Petrópolis - UNIFASE, Petrópolis, RJ
E-mail: iriseccard445@gmail.com
Lattes: <https://lattes.cnpq.br/3479753533578245>

Humberto Rabelo

Professor do Departamento de Computação e Tecnologia da UFRN
Universidade Federal do Rio Grande do Norte, Natal RN
E-mail: hlabeloufrn@gmail.com
Lattes: <https://lattes.cnpq.br/4563502602959752>
ORCID: <https://orcid.org/0000-0002-2246-1073>

Anderson Fernandes de Carvalho Farias

Mestre Internacional em Medicina
Esneca Business School - ESNECA, Zaragora AR
E-mail: andersonfercalho@gmail.com
Lattes: <https://lattes.cnpq.br/3357217652638543>
ORCID: <https://orcid.org/0000-0002-4326-9689>

Rafael Cordeiro Puhl

Graduado em Medicina
Universidade do Sul de Santa Catarina - UNISUL, Florianópolis SC
E-mail: rafaelc.puhl@gmail.com
Lattes: <https://lattes.cnpq.br/2838204887972323>
ORCID: <https://orcid.org/0009-0002-1891-2617>

Angélica Monteiro de Araújo

Graduanda em Enfermagem
Centro Universitário Estácio de Sá - ESTÁCIO, Maricá RJ
E-mail: angelmontaraujo@gmail.com

Artenes da Silva Cabral Neto

Graduando em Medicina
Faculdade de Medicina de Olinda - FMO, Olinda PE
E-mail: netopm_2009@hotmail.com
Lattes: <https://lattes.cnpq.br/2860903666900845>

Renata Laís Gouveia Santos

Graduanda em Medicina
Faculdade de Medicina de Olinda - FMO, Olinda PE
E-mail: renatinhalais90@gmail.com
Lattes: <https://lattes.cnpq.br/4477267210981772>

RESUMO

A crescente complexidade do diagnóstico oncológico, associada à heterogeneidade tumoral e às limitações dos métodos tradicionais, evidencia a necessidade de abordagens que reduzam as incertezas clínicas e aprimorem a tomada de decisão. Nesse contexto, a inferência bayesiana emerge como uma ferramenta relevante ao possibilitar a integração entre probabilidades prévias e novas evidências clínicas. O presente estudo teve como objetivo analisar a aplicação da inferência bayesiana na redução de incertezas diagnósticas em câncer, por meio de uma revisão integrativa da literatura. A busca foi realizada nas bases SciELO, PubMed e Scopus, considerando publicações entre 2021 e 2026, nos idiomas português, inglês e espanhol. Foram incluídos estudos que abordaram o uso de métodos bayesianos no diagnóstico, prognóstico e condução de ensaios clínicos em oncologia. Os resultados evidenciaram que a inferência bayesiana contribui significativamente para o aprimoramento do raciocínio clínico, ao permitir a atualização contínua das probabilidades diagnósticas e reduzir vieses cognitivos. Além disso, sua aplicação em modelos preditivos, análise de sobrevivência e ensaios clínicos adaptativos demonstrou maior flexibilidade metodológica e robustez estatística, especialmente em cenários de alta incerteza e amostras reduzidas. Destaca-se ainda seu papel na oncologia de precisão, ao integrar dados clínicos e moleculares para personalização do cuidado. Conclui-se que a inferência bayesiana representa uma abordagem promissora para qualificar o diagnóstico oncológico, contribuindo para decisões mais seguras e fundamentadas.

Palavras-chave: Câncer; Diagnóstico; Inferência Bayesiana; Incerteza Diagnóstica; Oncologia.

1 INTRODUÇÃO

A complexidade inerente ao diagnóstico oncológico representa um dos maiores desafios contemporâneos na área da saúde, sobretudo em função da variabilidade biológica dos tumores, da heterogeneidade clínica dos pacientes e da limitação dos métodos diagnósticos tradicionais. Nesse contexto, a tomada de decisão clínica frequentemente ocorre sob condições de incerteza, o que pode comprometer a precisão diagnóstica e, conseqüentemente, a efetividade das intervenções terapêuticas. A medicina baseada em evidências tem buscado estratégias que minimizem tais incertezas, destacando-se, entre elas, o uso de abordagens probabilísticas avançadas, como a inferência bayesiana, que permite integrar informações prévias com dados clínicos atuais para aprimorar o raciocínio diagnóstico (Sousa; Aguiar, 2022).

A inferência bayesiana fundamenta-se no teorema de Bayes, o qual possibilita a atualização contínua das probabilidades à medida que novas evidências são incorporadas ao processo decisório. Essa abordagem tem sido amplamente discutida como uma ferramenta pedagógica e prática no contexto clínico, promovendo maior acurácia diagnóstica ao considerar tanto a probabilidade pré-teste quanto os resultados de exames complementares (Lorca; Aguila, 2024). Além disso, sua aplicabilidade transcende o ensino, sendo incorporada em estudos clínicos e modelos estatísticos avançados, o que reforça sua relevância na medicina contemporânea, especialmente em áreas complexas como a oncologia (Taylor *et al.*, 2025).

Nesse sentido, a Figura 1 ilustra o processo de atualização probabilística característico da inferência bayesiana, evidenciando a relação entre conhecimento prévio, evidência observada e probabilidade posterior no contexto diagnóstico.

Figura 1 – Esquema da Inferência Bayesiana no Processo Diagnóstico

$$P(H | E) = \frac{P(E | H) \cdot P(H)}{P(E)}$$

Fonte: A matemática por trás das decisões clínicas (2024)

A inferência bayesiana, representada na Figura 1, fundamenta-se na atualização contínua das probabilidades à medida que novas evidências são incorporadas ao processo de análise. Nessa perspectiva, a probabilidade posterior $P(H/E)$ expressa a chance de uma hipótese H ser verdadeira após a observação de uma evidência E , sendo calculada a partir da probabilidade prévia $P(H)$, que reflete o conhecimento inicial, e da verossimilhança $P(E/H)$, que indica o grau de compatibilidade entre a evidência observada e a hipótese considerada. O termo $P(E)$, por sua vez, atua como fator de normalização, garantindo que as probabilidades resultantes sejam consistentes dentro do modelo.

A aplicação da inferência bayesiana no diagnóstico do câncer tem se mostrado particularmente promissora, uma vez que possibilita a integração de múltiplas fontes de dados, incluindo exames laboratoriais, achados de imagem, informações genômicas e histórico clínico do paciente. Evidências recentes indicam que modelos bayesianos são capazes de aumentar a precisão na predição de prognóstico e na detecção precoce de neoplasias, favorecendo decisões clínicas mais assertivas (Chu *et al.*, 2022; Teng *et al.*, 2022). Além disso, a utilização de modelos dinâmicos e adaptativos permite o acompanhamento da evolução da doença ao longo do tempo, ajustando continuamente as estimativas de risco (Zhou *et al.*, 2021).

Outro aspecto relevante refere-se à capacidade da inferência bayesiana de lidar com cenários caracterizados por amostras reduzidas e dados incompletos, situação recorrente em estudos oncológicos, especialmente em cânceres raros ou em fases iniciais de investigação clínica. Nesse contexto, a incorporação de evidências prévias e o uso de métodos como o information borrowing tornam-se essenciais para aumentar a robustez das análises e reduzir a incerteza associada às estimativas (Sondhi *et al.*, 2021; Su *et al.*, 2022). Tal característica confere à abordagem bayesiana uma vantagem significativa em relação aos métodos frequentistas tradicionais, que, em geral, dependem de grandes amostras para garantir validade estatística.

Adicionalmente, a inferência bayesiana tem sido amplamente aplicada no desenvolvimento e na análise de ensaios clínicos em oncologia, contribuindo para a construção de desenhos experimentais mais flexíveis e eficientes. Modelos bayesianos permitem adaptações ao longo do estudo, como ajustes de dose, interrupção precoce por eficácia ou futilidade e incorporação de dados externos, otimizando o processo de desenvolvimento de novas terapias (Chen *et al.*, 2022; Song; Wen, 2023). Paralelamente, abordagens inovadoras, como modelos generativos bayesianos e análises de sobrevivência informadas, têm ampliado as possibilidades de compreensão da dinâmica tumoral e da resposta terapêutica (Pourzanjani *et al.*, 2024; Bartoš *et al.*, 2022).

No âmbito da oncologia de precisão, a integração de dados multiômicos com modelos bayesianos tem potencializado a personalização do cuidado, permitindo a identificação mais acurada de biomarcadores e a estratificação de pacientes. Essa abordagem favorece decisões terapêuticas individualizadas, contribuindo para a redução das incertezas e o aumento da efetividade clínica (Correa-Aguila *et al.*,

2022). De forma complementar, ferramentas bayesianas vêm sendo incorporadas em ambientes de decisão clínica, como os tumor boards, auxiliando profissionais na interpretação de dados complexos e na definição de condutas mais adequadas (Pasetto *et al.*, 2021).

Além disso, a análise bayesiana tem sido empregada na avaliação de intervenções terapêuticas, incluindo radioterapia e esquemas farmacológicos, proporcionando uma compreensão mais aprofundada dos efeitos do tratamento em contextos reais (Fornacon-Wood *et al.*, 2022). A utilização de modelos preditivos avançados, como redes bayesianas profundas e modelos de sobrevivência com múltiplos pontos de mudança, reforça o potencial dessa abordagem na antecipação de desfechos clínicos e na redução de incertezas prognósticas (Zhang *et al.*, 2022; Xu, 2026).

Outro ponto relevante refere-se à aplicabilidade da inferência bayesiana na validação de instrumentos e métricas em saúde, como evidenciado pelo uso do coeficiente ômega bayesiano, que contribui para maior precisão na avaliação da confiabilidade de medidas clínicas e psicométricas (Banos-Chaparro; Caycho-Rodriguez, 2024). Esse avanço metodológico fortalece a qualidade das evidências utilizadas no processo diagnóstico e terapêutico, ampliando a segurança das decisões clínicas.

Diante desse contexto, observa-se que a inferência bayesiana se consolida como uma ferramenta robusta e versátil na redução de incertezas diagnósticas em câncer, ao integrar diferentes fontes de informação e promover uma abordagem mais dinâmica, adaptativa e personalizada da prática clínica. Sua aplicação abrange desde o raciocínio clínico individual até o desenvolvimento de ensaios clínicos e modelos preditivos complexos, evidenciando seu impacto significativo na oncologia contemporânea.

Assim, o presente estudo tem como objetivo analisar a aplicação da inferência bayesiana como ferramenta para a redução de incertezas diagnósticas em câncer, destacando suas contribuições para o aprimoramento do raciocínio clínico, da tomada de decisão e da precisão diagnóstica no contexto oncológico.

2 METODOLOGIA

Trata-se de uma revisão integrativa da literatura, de caráter qualitativo e abordagem descritivo-analítica, cujo objetivo foi reunir, analisar e sintetizar evidências científicas acerca da aplicação da inferência bayesiana como ferramenta para a redução de incertezas diagnósticas em câncer. A escolha por esse tipo de revisão justifica-se por sua capacidade de integrar resultados de estudos com diferentes delineamentos metodológicos, possibilitando uma compreensão abrangente do fenômeno investigado e contribuindo para a consolidação do conhecimento na área.

A condução do estudo foi orientada pelas seguintes etapas: (1) identificação do tema e elaboração da pergunta norteadora; (2) definição dos critérios de inclusão e exclusão; (3) estabelecimento da estratégia

de busca; (4) seleção dos estudos; (5) análise e interpretação dos resultados; e (6) síntese do conhecimento. Essas etapas foram organizadas de forma sistemática, garantindo rigor metodológico e reprodutibilidade do estudo.

A pergunta norteadora que guiou esta revisão foi: “Como a inferência bayesiana tem sido aplicada na redução de incertezas diagnósticas em câncer no contexto clínico e em pesquisas oncológicas?”. Tal questionamento foi estruturado de modo a abranger tanto aplicações práticas no raciocínio clínico quanto o uso de modelos bayesianos em estudos diagnósticos e prognósticos.

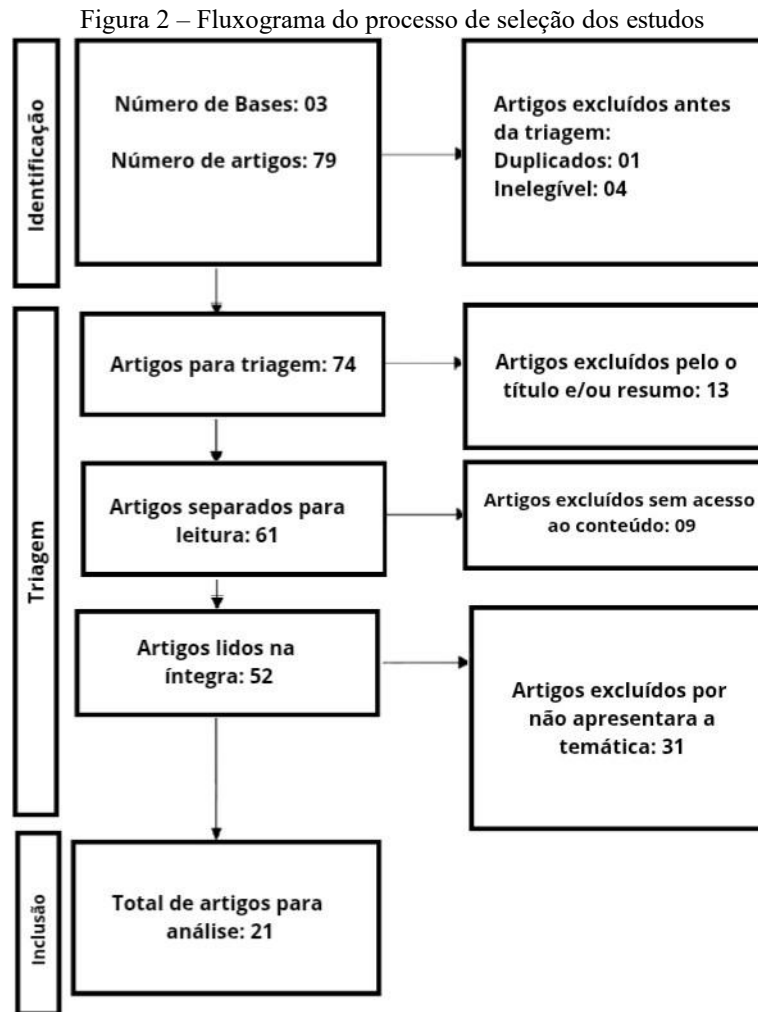
A busca dos estudos foi realizada nas bases de dados Scientific Electronic Library Online (SciELO), PubMed e Scopus, reconhecidas pela relevância e abrangência na área da saúde. Foram utilizados descritores controlados e não controlados, combinados por meio de operadores booleanos AND e OR, nos idiomas português, inglês e espanhol. Os principais descritores empregados foram: “Inferência Bayesiana”, “Bayesian Inference”, “Diagnóstico”, “Diagnosis”, “Câncer”, “Cancer”, “Oncologia”, “Oncology”, “Incerteza Diagnóstica” e “Diagnostic Uncertainty”. A estratégia de busca foi adaptada conforme as especificidades de cada base de dados, visando ampliar a sensibilidade e a abrangência da recuperação dos estudos.

Foram estabelecidos como critérios de inclusão: (a) artigos científicos publicados no período de 2021 a 2026; (b) estudos disponíveis na íntegra; (c) publicações nos idiomas português, inglês ou espanhol; (d) pesquisas que abordassem a aplicação da inferência bayesiana no contexto do diagnóstico, prognóstico ou tomada de decisão em oncologia; e (e) estudos com delineamentos metodológicos diversos, incluindo ensaios clínicos, estudos observacionais, revisões e modelagens estatísticas.

Como critérios de exclusão, adotaram-se: (a) artigos duplicados; (b) estudos que não respondiam à pergunta norteadora; (c) publicações incompletas, como resumos simples, editoriais, cartas ao editor e opiniões de especialistas sem respaldo metodológico; e (d) estudos cujo foco não estivesse diretamente relacionado ao uso de métodos bayesianos em oncologia.

O processo de seleção dos estudos ocorreu em três etapas: inicialmente, foi realizada a leitura dos títulos e resumos para identificação de potencial relevância; em seguida, procedeu-se à leitura na íntegra dos artigos pré-selecionados; por fim, os estudos que atenderam a todos os critérios estabelecidos foram incluídos na amostra final. Para garantir maior rigor, a seleção foi conduzida de forma criteriosa, priorizando estudos com maior nível de evidência e relevância científica.

Nesse contexto, a Figura 2 apresenta o fluxograma do processo de seleção dos estudos, detalhando as etapas de identificação, triagem, elegibilidade e inclusão, conforme os critérios estabelecidos nesta revisão.



Fonte: Autoria própria (2026)

A análise dos dados foi realizada por meio de leitura crítica e interpretação dos estudos incluídos, com posterior organização das informações em categorias temáticas, de acordo com os objetivos da pesquisa. Foram considerados aspectos como tipo de estudo, aplicação da inferência bayesiana, contexto clínico, contribuições para o diagnóstico oncológico e principais limitações apontadas pelos autores. Essa abordagem permitiu identificar padrões, lacunas e avanços no uso de métodos bayesianos na oncologia.

Por fim, a síntese dos resultados foi conduzida de forma narrativa e analítica, buscando articular os achados dos diferentes estudos e evidenciar as contribuições da inferência bayesiana para a redução de incertezas diagnósticas em câncer. O rigor metodológico adotado ao longo de todas as etapas visa assegurar a confiabilidade dos resultados apresentados e sua relevância para a prática clínica e para futuras pesquisas na área.

3 RESULTADOS E DISCUSSÃO

A análise dos estudos selecionados evidenciou que a aplicação da inferência bayesiana no

INFERÊNCIA BAYESIANA COMO FERRAMENTA PARA REDUÇÃO DE INCERTEZAS DIAGNÓSTICAS EM CÂNCER

contexto oncológico tem se expandido significativamente nos últimos anos, especialmente no que se refere à redução de incertezas diagnósticas, ao aprimoramento do raciocínio clínico e à construção de modelos preditivos mais robustos. Observou-se que os estudos incluídos apresentam diversidade metodológica, abrangendo ensaios clínicos, modelagens estatísticas, estudos observacionais e revisões teóricas, o que reforça a versatilidade da abordagem bayesiana na oncologia contemporânea. De modo geral, os achados apontam para três eixos principais de aplicação: (1) suporte ao raciocínio diagnóstico e à tomada de decisão clínica; (2) desenvolvimento de modelos prognósticos e preditivos; e (3) otimização de ensaios clínicos e avaliação de intervenções terapêuticas. Esses eixos refletem a amplitude de utilização da inferência bayesiana, desde o nível individual do paciente até o planejamento de pesquisas clínicas complexas.

Nesse contexto, o Quadro 1 sintetiza as principais características dos estudos analisados, incluindo autores, ano de publicação, tipo de estudo e principais contribuições relacionadas ao uso da inferência bayesiana na oncologia.

Quadro 1 – Caracterização dos estudos incluídos na revisão

Autor/Ano	Contexto de Aplicação	Síntese Analítica das Contribuições
Sousa; Aguiar (2022)	Educação médica e raciocínio clínico	Estruturação do raciocínio clínico probabilístico, integrando dedução e indução em uma abordagem bayesiana aplicada à tomada de decisão
Lorca; Aguila (2024)	Diagnóstico clínico	Aplicação do teorema de Bayes na qualificação do julgamento clínico e na redução de vieses cognitivos
Cerda <i>et al.</i> (2025); Taylor <i>et al.</i> (2025)	Ensaio clínico	Consolidação da análise bayesiana como alternativa interpretativa mais flexível e clinicamente significativa em estudos experimentais
Sondhi <i>et al.</i> (2021); Su <i>et al.</i> (2022)	Pequenas amostras e integração de dados	Fortalecimento da inferência em cenários de alta incerteza por meio da incorporação de evidências externas (information borrowing)

Chen <i>et al.</i> (2022); Song; Wen (2023)	Ensaio clínico oncológico	Desenvolvimento de modelos adaptativos bayesianos, ampliando a eficiência e a flexibilidade metodológica
Chu <i>et al.</i> (2022)	Prognóstico em câncer	Integração de dados clínicos e moleculares para construção de modelos prognósticos mais precisos
Teng <i>et al.</i> (2022); Zhang <i>et al.</i> (2022)	Prognóstico oncológico	Uso de modelos dinâmicos e redes bayesianas profundas para aprimorar a predição de desfechos clínicos
Zhou <i>et al.</i> (2021); Bartoš <i>et al.</i> (2022)	Modelos de sobrevivência	Aplicação de média bayesiana e modelos informados para maior robustez na análise de dados longitudinais
Yao <i>et al.</i> (2023)	Imuno-oncologia	Modelagem longitudinal integrada para análise de desfechos clínicos complexos
Fornacon-Wood <i>et al.</i> (2022); Pourzanjani <i>et al.</i> (2024); Xu (2026)	Dinâmica tumoral e intervenções	Ampliação da compreensão da evolução tumoral e dos efeitos terapêuticos por meio de modelos bayesianos avançados
Pasetto <i>et al.</i> (2021); Correa-Aguila <i>et al.</i> (2022); Agema <i>et al.</i> (2025)	Oncologia de precisão e decisão clínica	Integração de dados complexos e suporte à decisão clínica personalizada em ambientes multidisciplinares
Banos-Chaparro; Caycho-Rodriguez (2024)	Validação de instrumentos	Aplicação do coeficiente ômega bayesiano para maior precisão na avaliação da confiabilidade de medidas

Fonte: Autoria própria (2026)

A partir da análise dos estudos, verificou-se que a inferência bayesiana tem sido amplamente utilizada como ferramenta de apoio ao raciocínio clínico, permitindo a integração de probabilidades prévias com novas evidências diagnósticas. Segundo Sousa e Aguiar (2022), essa abordagem contribui para o

desenvolvimento de um raciocínio clínico mais estruturado, ao articular elementos dedutivos e indutivos em um modelo probabilístico dinâmico. Corroborando essa perspectiva, Lorca e Aguila (2024) destacam que a aplicação do teorema de Bayes no processo diagnóstico favorece decisões mais fundamentadas, reduzindo vieses cognitivos e aumentando a acurácia clínica.

No que se refere aos modelos prognósticos, os estudos analisados demonstram avanços significativos na utilização de métodos bayesianos para predição de desfechos em câncer. Chu *et al.* (2022) evidenciam que esses modelos permitem integrar dados clínicos e moleculares, resultando em estimativas mais precisas de prognóstico. De forma complementar, Teng *et al.* (2022) apresentam um modelo bayesiano dinâmico aplicado ao câncer de mama, capaz de atualizar continuamente as previsões de sobrevivência com base em novos dados clínicos. Ainda nesse contexto, Zhang *et al.* (2022) destacam o uso de redes bayesianas profundas, que ampliam a capacidade de modelagem de relações complexas entre variáveis clínicas.

Outro aspecto relevante identificado nos estudos refere-se à aplicação da inferência bayesiana em ensaios clínicos oncológicos. Taylor *et al.* (2025) enfatizam que essa abordagem permite maior flexibilidade nos desenhos experimentais, possibilitando adaptações ao longo do estudo com base em evidências emergentes. Chen *et al.* (2022) destacam o uso de desenhos em duas etapas, que otimizam a avaliação de eficácia terapêutica, enquanto Song e Wen (2023) apontam a relevância de desenhos inovadores na neuro-oncologia. Ademais, Cerda *et al.* (2025) ressaltam que a análise bayesiana de ensaios clínicos proporciona interpretações mais intuitivas dos resultados, facilitando a tomada de decisão clínica.

Os estudos também evidenciam a importância da inferência bayesiana na análise de dados com amostras reduzidas e alta incerteza. Sondhi *et al.* (2021) demonstram que a incorporação de evidências adicionais melhora a robustez das estimativas, enquanto Su *et al.* (2022) discutem métodos de “information borrowing” como estratégia para integrar dados de diferentes fontes. Zhou *et al.* (2021) complementam essa análise ao apresentar modelos de mediação baseados em média bayesiana, que permitem compreender relações complexas entre variáveis em estudos de sobrevivência.

Além disso, a inferência bayesiana tem sido aplicada na avaliação de intervenções terapêuticas e na modelagem da dinâmica tumoral. Fornacon-Wood *et al.* (2022) destacam sua utilidade na análise de dados do mundo real em radioterapia, enquanto Pourzanjani *et al.* (2024) apresentam modelos generativos capazes de estimar a evolução tumoral a partir de dados publicados. Xu (2026) reforça essa abordagem ao propor modelos de sobrevivência com múltiplos pontos de mudança, ampliando a capacidade de detecção de padrões clínicos relevantes.

No campo da oncologia de precisão, Correa-Aguila *et al.* (2022) evidenciam que a integração de dados multiômicos com modelos bayesianos permite maior acurácia na identificação de biomarcadores, contribuindo para a personalização do tratamento. Pasetto *et al.* (2021) complementam essa perspectiva ao

demonstrar a aplicabilidade de frameworks bayesianos em tumor boards, auxiliando na tomada de decisão clínica multidisciplinar.

Adicionalmente, Bartoš *et al.* (2022) destacam a importância da análise de sobrevivência bayesiana informada, enquanto Yao *et al.* (2023) apresentam modelos de média preditiva aplicados a ensaios clínicos em imuno-oncologia. Agema *et al.* (2025) apontam para a aplicação de modelos bayesianos na otimização de doses em oncologia, reforçando a relevância dessa abordagem na prática clínica.

Por fim, Banos-Chaparro e Caycho-Rodriguez (2024) evidenciam a aplicação do coeficiente ômega bayesiano na validação de instrumentos em saúde, contribuindo para maior precisão na mensuração de variáveis clínicas e psicométricas.

O Quadro 2 apresenta a síntese das principais contribuições da inferência bayesiana na oncologia, organizadas por categorias temáticas identificadas na análise.

Quadro 2 – Síntese das contribuições da inferência bayesiana na oncologia

Categoria Analítica	Dimensão de Aplicação	Contribuições Epistemológicas e Clínicas
Raciocínio clínico probabilístico	Integração entre probabilidade pré-teste e pós-teste	Reestruturação do processo diagnóstico com base em inferência probabilística, reduzindo vieses cognitivos e promovendo decisões mais racionais
Diagnóstico oncológico	Interpretação integrada de dados clínicos, laboratoriais e de imagem	Ampliação da acurácia diagnóstica por meio da atualização contínua das probabilidades
Modelagem prognóstica	Predição de sobrevivência e progressão tumoral	Desenvolvimento de modelos dinâmicos e adaptativos, capazes de incorporar novas evidências ao longo do tempo
Ensaio clínicos adaptativos	Planejamento e análise de estudos experimentais	Flexibilização metodológica, permitindo ajustes dinâmicos e maior eficiência na produção de evidências
Gestão de incerteza em pequenas amostras	Integração de dados prévios e externos	Redução da variabilidade estatística e aumento da robustez inferencial

INFERÊNCIA BAYESIANA COMO FERRAMENTA PARA REDUÇÃO DE INCERTEZAS DIAGNÓSTICAS EM CÂNCER

Oncologia de precisão	Integração de dados multiômicos e clínicos	Personalização terapêutica baseada em perfis biológicos individuais
Modelagem da dinâmica tumoral	Análise longitudinal e simulação de cenários clínicos	Compreensão ampliada da evolução da doença e resposta ao tratamento
Avaliação de intervenções terapêuticas	Análise de eficácia em contextos reais	Suporte à tomada de decisão clínica com base em evidências probabilísticas
Decisão clínica multidisciplinar	Aplicação em tumor boards	Integração de múltiplas fontes de conhecimento e especialidades
Validação de instrumentos	Avaliação da confiabilidade de medidas	Fortalecimento da qualidade metodológica e da precisão das inferências clínicas

Fonte: Autoria própria (2026)

A análise dos estudos evidencia que a inferência bayesiana representa uma mudança paradigmática na forma como a incerteza é compreendida e gerenciada no contexto oncológico. Diferentemente das abordagens tradicionais, que frequentemente tratam a incerteza como uma limitação metodológica, o modelo bayesiano a incorpora como elemento central do processo analítico, permitindo sua quantificação e atualização contínua. Nesse sentido, Sousa e Aguiar (2022) destacam que o raciocínio clínico baseado em probabilidades favorece decisões mais consistentes, ao integrar múltiplas fontes de informação de maneira estruturada.

A aplicabilidade dessa abordagem no diagnóstico do câncer revela-se particularmente relevante diante da complexidade inerente à doença. Lorca e Aguila (2024) argumentam que a utilização do teorema de Bayes no processo diagnóstico contribui para a redução de vieses cognitivos, frequentemente associados à interpretação subjetiva de dados clínicos. Essa perspectiva é reforçada por Taylor *et al.* (2025), ao afirmarem que a análise bayesiana proporciona interpretações mais intuitivas e clinicamente relevantes dos resultados, facilitando a tomada de decisão.

No âmbito dos modelos prognósticos, observa-se que a inferência bayesiana permite avanços significativos na predição de desfechos clínicos. Chu *et al.* (2022) destacam que a integração de dados clínicos e moleculares amplia a capacidade preditiva dos modelos, enquanto Teng *et al.* (2022) evidenciam a importância de modelos dinâmicos na atualização contínua das estimativas de risco. Ademais, Zhang *et al.* (2022) demonstram que o uso de redes bayesianas profundas possibilita a modelagem de relações complexas, contribuindo para maior precisão prognóstica.

Outro aspecto relevante refere-se à flexibilidade dos desenhos de ensaios clínicos baseados em inferência bayesiana. Chen *et al.* (2022) enfatizam que modelos adaptativos permitem ajustes ao longo do estudo, otimizando recursos e aumentando a eficiência das pesquisas. Song e Wen (2023) complementam essa análise ao destacar a importância de desenhos inovadores na neuro-oncologia, enquanto Cerda *et al.* (2025) ressaltam a relevância da interpretação probabilística dos resultados para a prática clínica.

A capacidade de lidar com amostras reduzidas e dados incompletos constitui uma das principais vantagens da abordagem bayesiana. Sondhi *et al.* (2021) demonstram que a incorporação de evidências adicionais melhora a robustez das análises, enquanto Su *et al.* (2022) destacam o papel do “information borrowing” na integração de dados de diferentes fontes. Zhou *et al.* (2021) reforçam essa perspectiva ao apresentar modelos de média bayesiana que permitem compreender relações complexas em estudos de sobrevivência.

No contexto da oncologia de precisão, a integração de dados multiômicos representa um avanço significativo na personalização do cuidado. Correa-Aguila *et al.* (2022) argumentam que a combinação de diferentes camadas de informação biológica, aliada a modelos bayesianos, permite maior acurácia na identificação de biomarcadores. Pasetto *et al.* (2021) acrescentam que frameworks bayesianos podem ser incorporados em ambientes de decisão clínica, promovendo uma abordagem mais colaborativa e fundamentada.

Além disso, a aplicação da inferência bayesiana na avaliação de intervenções terapêuticas e na modelagem da dinâmica tumoral amplia as possibilidades de compreensão da doença. Fornacon-Wood *et al.* (2022) destacam sua utilidade na análise de dados do mundo real, enquanto Pourzanjani *et al.* (2024) e Xu (2026) evidenciam avanços na modelagem de processos dinâmicos e na identificação de padrões clínicos.

Por fim, a utilização de métricas bayesianas na validação de instrumentos reforça a qualidade das evidências científicas. Banos-Chaparro e Caycho-Rodriguez (2024) destacam que o coeficiente ômega bayesiano proporciona maior precisão na avaliação da confiabilidade, contribuindo para decisões clínicas mais seguras.

Dessa forma, a inferência bayesiana consolida-se como uma ferramenta essencial na oncologia contemporânea, não apenas pela sua capacidade de reduzir incertezas diagnósticas, mas também por promover uma abordagem mais integrada, adaptativa e centrada no paciente. Seus avanços metodológicos e aplicações práticas indicam um caminho promissor para o aprimoramento da prática clínica e da pesquisa em saúde, especialmente em cenários marcados por alta complexidade e incerteza.

4 CONCLUSÃO

A presente revisão integrativa permitiu compreender, de forma abrangente, o papel da inferência bayesiana como ferramenta estratégica na redução de incertezas diagnósticas no contexto oncológico, evidenciando sua relevância tanto no raciocínio clínico quanto no desenvolvimento de modelos estatísticos aplicados à prática em saúde. Retomando o objetivo proposto, que consistiu em analisar a aplicação dessa abordagem na diminuição das incertezas diagnósticas em câncer, observa-se que os resultados alcançados atendem plenamente à problemática investigada, ao demonstrar que a inferência bayesiana contribui de maneira significativa para o aprimoramento da tomada de decisão clínica.

No que se refere à pergunta norteadora, os achados indicam que sua aplicação ocorre de forma transversal e integrada, abrangendo desde o suporte ao raciocínio clínico individual até a construção de modelos preditivos e a condução de ensaios clínicos. Nesse sentido, verificou-se que a utilização de probabilidades atualizáveis permite maior precisão na interpretação de dados clínicos e diagnósticos, reduzindo a subjetividade e promovendo decisões mais fundamentadas.

Entre os principais resultados identificados, destaca-se a capacidade da inferência bayesiana de integrar múltiplas fontes de informação, incluindo dados clínicos, laboratoriais, de imagem e moleculares, favorecendo uma abordagem diagnóstica mais robusta e dinâmica. Além disso, evidenciou-se sua aplicabilidade em cenários de elevada incerteza, como estudos com amostras reduzidas, nos quais métodos tradicionais apresentam limitações. A flexibilidade dos modelos bayesianos, especialmente em ensaios clínicos adaptativos e na modelagem de sobrevivência, também se configura como um diferencial relevante, ampliando a eficiência metodológica e a confiabilidade dos resultados.

Outro aspecto importante refere-se às contribuições da inferência bayesiana para a oncologia de precisão, na medida em que possibilita a personalização das decisões terapêuticas a partir da integração de dados complexos e heterogêneos. A incorporação dessa abordagem em ambientes de decisão clínica, como os tumor boards, reforça seu potencial para qualificar o cuidado multidisciplinar, promovendo maior alinhamento entre evidências científicas e prática clínica. Ademais, sua utilização na avaliação de intervenções terapêuticas e na modelagem da dinâmica tumoral evidencia avanços significativos na compreensão da evolução da doença.

As contribuições desta pesquisa residem, sobretudo, na sistematização do conhecimento acerca das aplicações da inferência bayesiana na oncologia, destacando sua relevância como ferramenta metodológica e clínica. Ao reunir evidências recentes e diversificadas, o estudo amplia a compreensão sobre as potencialidades dessa abordagem, além de evidenciar lacunas que podem orientar futuras investigações. Dessa forma, reforça-se a importância da incorporação de métodos probabilísticos avançados na formação e na prática dos profissionais de saúde, especialmente em contextos marcados por alta complexidade diagnóstica.

Por fim, sugere-se a realização de pesquisas empíricas no contexto brasileiro, especialmente em serviços oncológicos do Sistema Único de Saúde, com o objetivo de avaliar a aplicabilidade prática de modelos bayesianos na rotina clínica e seus impactos na qualidade do diagnóstico e na tomada de decisão. Estudos que integrem dados reais de pacientes, associando ferramentas bayesianas a sistemas de apoio à decisão clínica, podem contribuir significativamente para a consolidação dessa abordagem, promovendo avanços na precisão diagnóstica e na qualidade do cuidado em oncologia.

REFERÊNCIAS

- AGEMA, B. C.; KOCH, B. C. P.; MATHIJSSSEN, R. H. J.; KOOLEN, S. L. W. From prospective evaluation to practice: model-informed dose optimization in oncology. *Drugs*, v. 85, n. 4, p. 487-503, 2025.
- BANOS-CHAPARRO, Jonatan; CAYCHO-RODRIGUEZ, Tomás. Coeficiente ômega bayesiano: aplicaciones en ciencias de la salud. *Medicina Clínica Social, Santa Rosa del Aguaray*, v. 8, n. 2, p. 244-247, 2024.
- BARTOŠ, F.; AUST, F.; HAAF, J. M. Informed Bayesian survival analysis. *BMC Medical Research Methodology*, v. 22, n. 1, p. 238, 2022.
- CERDA, Jaime et al. Bayesian analysis of a randomized controlled trial: mathematical and clinical aspects. *Revista Chilena de Infectología, Santiago*, v. 42, n. 2, p. 157-165, 2025.
- CHEN, L.; PAN, J.; WU, Y.; WANG, J.; CHEN, F.; ZHAO, J.; CHEN, P. Bayesian two-stage design for phase II oncology trials with binary endpoint. *Statistics in Medicine*, v. 41, n. 12, p. 2291-2301, 2022.
- CHU, J.; SUN, N. A.; HU, W.; CHEN, X.; YI, N.; SHEN, Y. The application of Bayesian methods in cancer prognosis and prediction. *Cancer Genomics & Proteomics*, v. 19, n. 1, p. 1-11, 2022.
- CORREA-AGUILA, Raidel; ALONSO-PUPO, Niuxia; HERNÁNDEZ-RODRÍGUEZ, Erix W. Multi-omics data integration approaches for precision oncology. *Molecular Omics*, v. 18, n. 6, p. 469-479, 2022.
- FORNACON-WOOD, I.; MISTRY, H.; JOHNSON-HART, C.; FAIVRE-FINN, C.; O'CONNOR, J. P. B.; PRICE, G. J. Bayesian methods provide a practical real-world evidence framework for evaluating the impact of changes in radiotherapy. *Radiotherapy and Oncology*, v. 176, p. 53-58, 2022.
- LORCA, Jaime Cerda; AGUILA, Lorena Cifuentes. Inferencia bayesiana en el proceso de diagnóstico clínico: un enfoque docente para la toma de decisiones. *Revista Chilena de Infectología, Santiago*, v. 41, n. 6, p. 762-768, 2024.
- PASETTO, S.; GATENBY, R. A.; ENDERLING, H. Bayesian framework to augment tumor board decision making. *JCO Clinical Cancer Informatics*, v. 5, p. 508-517, 2021.
- POURZANJANI, A.; MODI, S.; CONNARN, J.; ZHANG, X.; UPRETI, V.; LIN, C. W.; MEHTA, K. A novel Bayesian generative approach for estimating tumor dynamics from published studies.

CPT: Pharmacometrics & Systems Pharmacology, v. 13, n. 8, p. 1341-1353, 2024.

SONDHI, A.; SEGAL, B.; SNIDER, J.; HUMBLET, O.; MCCUSKER, M. Bayesian additional evidence for decision making under small sample uncertainty. BMC Medical Research Methodology, v. 21, n. 1, p. 221, 2021.

SONG, K. W.; WEN, P. Y. Novel trial designs in neuro-oncology. Current Opinion in Neurology, v. 36, n. 6, p. 571-578, 2023.

SOUSA, Marcos Roberto; AGUIAR, Thiago Ribeiro Xavier de. Dedução, indução e a arte do raciocínio clínico na educação médica: revisão sistemática e proposta bayesiana. Arquivos Brasileiros de Cardiologia, v. 119, n. 5, p. 27-34, 2022.

SU, L.; CHEN, X.; ZHANG, J.; YAN, F. Comparative study of Bayesian information borrowing methods in oncology clinical trials. JCO Precision Oncology, v. 6, e2100394, 2022.

TAYLOR, C.; PUXTY, K.; QUASIM, T.; SHAW, M. Understanding Bayesian analysis of clinical trials: an overview for clinicians. Critical Care Science, v. 37, e20250267, 2025.

TENG, J.; ZHANG, H.; LIU, W.; SHU, X. O.; YE, F. A dynamic Bayesian model for breast cancer survival prediction. IEEE Journal of Biomedical and Health Informatics, v. 26, n. 11, p. 5716-5727, 2022.

XU, J. Bayesian analyses of multiple random change points in survival models with applications to clinical trials. Journal of Biopharmaceutical Statistics, v. 36, n. 2, p. 195-212, 2026.

YAO, Z.; MORITA, S.; NISHIDA, S.; SUGIYAMA, H. Bayesian predictive model averaging approach to joint longitudinal-survival modeling: application to an immuno-oncology clinical trial. Statistics in Medicine, v. 42, n. 27, p. 4990-5006, 2023.

ZHANG, Z.; CHAI, H.; WANG, Y.; PAN, Z.; YANG, Y. Cancer survival prognosis with deep Bayesian perturbation Cox network. Computers in Biology and Medicine, v. 141, p. 105012, 2022.

ZHOU, J.; JIANG, X.; XIA, H. A.; WEI, P.; HOBBS, B. P. A survival mediation model with Bayesian model averaging. Statistical Methods in Medical Research, v. 30, n. 11, p. 2413-2427, 2021.