

UNIVERSIDADE FEDERAL DE SERGIPE

CENTRO DE CIÊNCIAS EXATAS E TECNOLOGIA

PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO

Geração de Dados Totalmente Sintéticos para Alta Segura Neonatal: Uma Metodologia Orientada por Conhecimento Baseada em Redes Bayesianas

Dissertação de Mestrado

Jean Louis Silva Santos



São Cristóvão – Sergipe

2026

UNIVERSIDADE FEDERAL DE SERGIPE

CENTRO DE CIÊNCIAS EXATAS E TECNOLOGIA

PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO

Jean Louis Silva Santos

Geração de Dados Totalmente Sintéticos para Alta Segura Neonatal: Uma Metodologia Orientada por Conhecimento Baseada em Redes Bayesianas

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Ciência da Computação da Universidade Federal de Sergipe como requisito parcial para a obtenção do título de mestre em Ciência da Computação.

Orientador(a): Gilton J. F. da Silva
Coorientador(a): Josielson C. da Silva

São Cristóvão – Sergipe

2026

FICHA CATALOGRÁFICA ELABORADA PELA BIBLIOTECA CENTRAL
UNIVERSIDADE FEDERAL DE SERGIPE

Santos, Jean Louis Silva
S237s Geração de dados totalmente sintéticos para alta segura neonatal: uma metodologia orientada por conhecimento baseada em redes bayesianas / Jean Louis Silva Santos ; orientador Gilton J. F. da Silva. - São Cristóvão, 2026.
132 f.; il.

Dissertação (mestrado em Ciência da Computação) – Universidade Federal de Sergipe, 2026.

1. Computação. 2. Teoria bayesiana de decisão estatística. 3. Neonatologia. I. Silva, Gilton J. F. da orient. II. Título.

CDU 004

Dedico este trabalho
À minha mãe, Percilia, e ao meu pai, José (in memoriam), que me ensinaram o valor de cada momento.
Às minhas filhas Lavínia, Maria Eduarda e Júlia, e ao meu filho Oliver, razões e destinos de cada esforço.
À minha esposa Liliane, companheira em cada momento.

Agradecimentos

A Deus, por ser fonte de força, sabedoria e perseverança em cada etapa desta caminhada acadêmica, sustentando-me nos momentos de cansaço e celebrando comigo cada conquista.

À minha mãe, Percilia, pelo amor incondicional, pelos valores que me formaram e pelo apoio constante que me trouxe até aqui.

Ao meu pai, José (in memoriam), pelo seu caráter e trabalho, e por me ensinar o valor da perseverança e da honestidade durante sua vida.

Às minhas filhas, Lavínia, Maria Eduarda e Júlia, e ao meu filho, Oliver, razões maiores de todo o meu esforço. Que este trabalho sirva de exemplo de que a dedicação e o estudo transformam realidades e iluminam caminhos.

À minha esposa, Liliane, por ser companheira em todos os sentidos e em todas as horas — pela paciência nas manhãs, tardes e noites de escrita, pela compreensão nas ausências necessárias e pelo incentivo diário que ajudou a tornar este trabalho possível.

Ao meu orientador, Prof. Dr. Gilton José, pela orientação segura, pelo rigor científico exigido em cada etapa e pela confiança depositada no desenvolvimento desta pesquisa.

Ao meu coorientador, Prof. Dr. Josielson Costa, pela parceria essencial, pelas contribuições clínicas fundamentais que deram sustentação e validade a este trabalho, e pela disponibilidade constante ao longo do processo.

Ao Programa de Pós-Graduação em Ciência da Computação da UFS (PROCC) e ao Programa de Pós-Graduação em Enfermagem e Saúde da UFBA (PPGENF), e a todos os professores e colegas que, direta ou indiretamente, contribuíram para a realização desta dissertação.

“Todas as artes contribuem para a maior de todas as artes, a arte de viver.” — Bertolt Brecht
(Citação utilizada no encerramento do Manual Técnico do Método Canguru, Brasil. Ministério da Saúde (2017))

Resumo

Contexto: A alta hospitalar do recém-nascido constitui uma etapa crítica da transição do cuidado, exigindo avaliação multidimensional de condições biofisiológicas, preventivas e assistenciais. **Problema**: Embora sistemas de apoio à decisão clínica baseados em Inteligência Artificial apresentem potencial para reduzir a variabilidade do julgamento profissional, seu desenvolvimento em neonatologia é limitado pela escassez de registros rotulados, pelas restrições legais ao uso de dados sensíveis e pelo problema de *cold start*. **Motivação**: A geração de dados totalmente sintéticos surge como alternativa para apoiar pesquisa, simulação e desenvolvimento computacional sem exposição direta de prontuários reais. **Justificativa**: Em domínios sensíveis como a neonatologia, abordagens sintéticas orientadas apenas por dados podem depender de bases reais prévias, reproduzir vieses ou gerar combinações clinicamente implausíveis, tornando relevante uma estratégia *knowledge-driven*, interpretável e auditável. **Metodologia**: Esta dissertação propõe e avalia uma metodologia baseada em Redes Bayesianas para geração de dados totalmente sintéticos aplicados ao suporte à decisão na alta segura neonatal, sem utilização de prontuários reais no processo de modelagem. A metodologia foi construída de forma incremental, partindo de um modelo inicial com 11 variáveis clínicas (Core11) e avançando para uma versão expandida com 18 variáveis (Core18). A topologia causal da rede, as Tabelas de Probabilidade Condicional (CPTs), os pesos normativos e as regras de auditoria clínica foram definidos a partir de literatura especializada, documentos normativos e curadoria de conhecimento clínico. A avaliação utilizou protocolos de validação interna, incluindo fidelidade estatística, inferência condicional, utilidade preditiva em regime *Train on Synthetic, Test on Synthetic* (TSTS), explicabilidade por SHAP, análise de limiares, auditoria de casos-limite, fidelidade topológica multivariada e edit checks clínicos. **Resultados**: Os experimentos principais foram conduzidos com 10.000 registros sintéticos em cada versão do modelo. No Core11, os resultados indicaram aprovação dos testes S1 e S2, Kappa médio de 0,9445 no protocolo S3, Distância de Hellinger aprovada em 11/11 variáveis e PCD-MAD de 0,0088 no protocolo S7. No Core18, a expansão manteve boa fidelidade estatística, topológica e inferencial, com S1 aprovado em 7/7 testes, S2 aprovado em 14/14 casos, Kappa médio de 0,9209, Distância de Hellinger aprovada em 18/18 variáveis e PCD-MAD de 0,0097. Entretanto, também foram observadas limitações relevantes, incluindo divergência entre importância explicativa e pesos normativos no S3SHAP, instabilidade dos limiares de decisão nos protocolos S4 e S5, e ocorrência de violações em edit checks clínicos em 36,9% dos registros sintéticos. **Conclusões**: Conclui-se que a abordagem proposta é promissora como metodologia de geração sintética *privacy-by-design* para cenários neonatais de *cold start*, especialmente por preservar propriedades probabilísticas e topológicas do modelo sem depender de dados reais. Ao mesmo tempo, os resultados demonstram que a coerência estatística global não garante, isoladamente, plausibilidade clínica individual plena. Assim, a principal contribuição da dissertação reside não apenas na geração de dados sintéticos neonatais, mas na formulação de um pipeline auditável de modelagem, validação e identificação de limites, indicando a necessidade

de mecanismos futuros de calibração, filtragem clínica, reamostragem condicionada e validação com especialistas.

Palavras-chave: Dados Sintéticos. Redes Bayesianas. Neonatologia. Alta Segura. Sistemas de Apoio à Decisão Clínica. Privacy-by-design.

Abstract

Context: Neonatal hospital discharge is a critical stage in the transition of care, requiring multidimensional assessment of biophysiological, preventive, and healthcare-related conditions. **Problem**: Although Artificial Intelligence-based Clinical Decision Support Systems have the potential to reduce variability in professional judgment, their development in neonatology is limited by the scarcity of labeled records, legal restrictions on the use of sensitive health data, and the *cold start* problem. **Motivation**: The generation of fully synthetic data emerges as an alternative to support research, simulation, and computational development without direct exposure of real medical records. **Justification**: In sensitive domains such as neonatology, synthetic approaches guided only by data may depend on prior real datasets, reproduce biases, or generate clinically implausible combinations, making a *knowledge-driven*, interpretable, and auditable strategy relevant. **Methodology**: This dissertation proposes and evaluates a Bayesian Network-based methodology for generating fully synthetic data applied to decision support in safe neonatal discharge, without using real medical records in the modeling process. The methodology was developed incrementally, starting from an initial model with 11 clinical variables (Core11) and advancing to an expanded version with 18 variables (Core18). The causal network topology, Conditional Probability Tables (CPTs), normative weights, and clinical audit rules were defined based on specialized literature, normative documents, and clinical knowledge curation. The evaluation used internal validation protocols, including statistical fidelity, conditional inference, predictive utility under a *Train on Synthetic, Test on Synthetic* (TSTS) regime, SHAP-based explainability, threshold analysis, borderline case auditing, multivariate topological fidelity, and clinical edit checks. **Results**: The main experiments were conducted with 10,000 synthetic records in each model version. In Core11, the results indicated approval in protocols S1 and S2, a mean Kappa of 0.9445 in protocol S3, Hellinger Distance approved in 11/11 variables, and PCD-MAD of 0.0088 in protocol S7. In Core18, the expansion maintained good statistical, topological, and inferential fidelity, with S1 approved in 7/7 tests, S2 approved in 14/14 cases, a mean Kappa of 0.9209, Hellinger Distance approved in 18/18 variables, and PCD-MAD of 0.0097. However, relevant limitations were also observed, including divergence between explanatory importance and normative weights in S3SHAP, instability of decision thresholds in protocols S4 and S5, and the occurrence of clinical edit check violations in 36.9% of the synthetic records. **Conclusions**: It is concluded that the proposed approach is promising as a *privacy-by-design* synthetic data generation methodology for neonatal *cold start* scenarios, especially because it preserves probabilistic and topological properties of the model without relying on real patient data. At the same time, the findings show that global statistical coherence alone does not guarantee full individual clinical plausibility. Thus, the main contribution of this dissertation lies not only in generating synthetic neonatal data, but also in formulating an auditable pipeline for modeling, validation, and identification of methodological limits, indicating the need for future mechanisms of calibration, clinical filtering, conditional resampling, and expert validation.

Keywords: Synthetic Data. Bayesian Networks. Neonatology. Safe Discharge. Clinical Decision Support Systems. Privacy-by-design.

Lista de ilustrações

Figura 1 – Pipeline metodológico de geração, classificação e validação dos dados sintéticos neonatais. 46
Figura 2 – Topologia da Rede Bayesiana na versão Core18. 52
Figura 3 – Síntese dos protocolos de validação interna aplicados aos modelos Core11 e Core18. 60
Figura 4 – Fluxograma das etapas de seleção das fontes da revisão estruturada 68
Figura 5 – Distribuição percentual das decisões de alta nas execuções oficiais Core11 e Core18, reconstruída a partir dos resultados experimentais exportados pelo algoritmo. 88
Figura 6 – Ranking de importância das variáveis no protocolo S3SHAP para o Core18. 90
Figura 7 – Comparação entre limiar normativo e limiar ótimo de Youden no protocolo S4 para o Core18. 92
Figura 8 – Distância de Hellinger por variável no protocolo S7 para o Core18. 93
Figura 9 – Distribuição das violações por edit check na execução oficial do Core18. . . 95

Lista de tabelas

Tabela 1 – Artefatos documentais utilizados na metodologia 48
Tabela 2 – Parâmetros de escore nas versões Core11 e Core18 58
Tabela 3 – Protocolos de validação utilizados na pesquisa 60
Tabela 4 – Execuções principais analisadas na dissertação 62
Tabela 5 – Síntese comparativa dos resultados metodológicos 63
Tabela 6 – Síntese comparativa dos trabalhos relacionados 74
Tabela 7 – Execuções oficiais analisadas 86
Tabela 8 – Distribuição das decisões de alta no Core11 86
Tabela 9 – Síntese dos protocolos de validação do Core11 87
Tabela 10 – Distribuição das decisões de alta no Core18 88
Tabela 11 – Resultados de S1 e S2 no Core18 89
Tabela 12 – Resultados de S3 e S3SHAP no Core18 91
Tabela 13 – Resultados dos protocolos de limiar no Core18 92
Tabela 14 – Resultados de S7 no Core18 93
Tabela 15 – Síntese do protocolo EC no Core18 94
Tabela 16 – Violações por edit check no Core18 95
Tabela 17 – Comparação dos principais resultados entre Core11 e Core18 96
Tabela 18 – Síntese das CPTs do Core18 114
Tabela 19 – Síntese das arestas da Rede Bayesiana (Core11 + Core18) 119
Tabela 20 – Síntese dos edit checks clínicos do Core18 123
Tabela 21 – Rastreabilidade dos artefatos metodológicos produzidos na pesquisa 127

Lista de algoritmos

1 Pipeline de geração e validação dos dados sintéticos 58

Lista de abreviaturas e siglas

ABNT	Associação Brasileira de Normas Técnicas
AIDPI	Atenção Integrada às Doenças Prevalentes na Infância
API	Application Programming Interface
AUC	Area Under the Curve
BN	Bayesian Network
C2ST	Classifier Two-Sample Test
Core11	Modelo nuclear com 11 variáveis clínicas
Core18	Modelo expandido com 18 variáveis clínicas
Core25	Modelo prospectivo com 25 variáveis, tratado como trabalho futuro
CPT	Conditional Probability Table
CSV	Comma-Separated Values
DAG	Directed Acyclic Graph
DOI	Digital Object Identifier
EC	Edit Check
F1	Medida F1, média harmônica entre precisão e revocação
IA	Inteligência Artificial
JSON	JavaScript Object Notation
JSD	Jensen-Shannon Divergence
K2	Algoritmo K2 para aprendizado estrutural de Redes Bayesianas
LGPD	Lei Geral de Proteção de Dados
MIA	Membership Inference Attack
OMS	Organização Mundial da Saúde
OPAS	Organização Pan-Americana da Saúde
PC	Algoritmo Peter-Clark para aprendizado estrutural de grafos causais

PCD	Pairwise Correlation Difference
PCD-MAD	Median Absolute Deviation da Pairwise Correlation Difference
PCD-MAX	Valor máximo da Pairwise Correlation Difference
PNAISC	Política Nacional de Atenção Integral à Saúde da Criança
RB	Rede Bayesiana
RN	Recém-nascido
ROC	Receiver Operating Characteristic
S1	Protocolo de validação de fidelidade estatística
S2	Protocolo de validação de inferência condicional
S3	Protocolo de validação de utilidade preditiva interna
S3SHAP	Protocolo de explicabilidade baseado em SHAP
S4	Protocolo de validação de limiar por curva ROC
S5	Protocolo de análise de sensibilidade dos limiares
S6	Protocolo de auditoria de casos-limite
S7	Protocolo de fidelidade topológica multivariada
SBP	Sociedade Brasileira de Pediatria
SHAP	SHapley Additive exPlanations
TSTR	Train on Synthetic, Test on Real
TSTS	Train on Synthetic, Test on Synthetic
UFBA	Universidade Federal da Bahia
UFS	Universidade Federal de Sergipe
UTI	Unidade de Terapia Intensiva
WHO	World Health Organization

Lista de símbolos

n	Número de registros ou amostras sintéticas geradas em uma execução experimental
i	Índice de um registro sintético durante o processo de amostragem
$P(\cdot)$	Probabilidade de ocorrência de um evento ou estado
$P(A \mid B)$	Probabilidade condicional do evento ou estado A dado o evento ou estado B
0	Probabilidade nula atribuída a combinações impossíveis ou proibidas por zeros estruturais
ρ	Coeficiente de correlação de Spearman utilizado na avaliação do alinhamento explicativo do S3SHAP
p	Valor de significância estatística associado ao teste de correlação
Δ	Diferença entre limiar ótimo e limiar normativo nos protocolos de validação de limiar
$\times$	Produto cartesiano ou combinação entre variáveis, usado para indicar pares avaliados
%	Percentual ou proporção relativa de registros em uma classe ou condição

Ata da Sessão Solene de Defesa da Dissertação do Curso o em Ciência da Computação-UFS.
Candidato: JEAN LOUIS SILVA SANTOS

Aos 30 dias do mês de julho do ano de dois mil e vinte seis, com início às 09hs, realizou-se na Sala de Seminários do PROCC da Universidade Federal de Sergipe, na Cidade Universitária Prof. José Aloísio de Campos, a Sessão Pública de Defesa de Dissertação de Mestrado do candidato **JEAN LOUIS SILVA SANTOS** que desenvolveu o trabalho intitulado: **"Geração de Dados Totalmente Sintéticos para Alta Segura Neonatal: Uma Metodologia Orientada por Conhecimento Baseada em Redes Bayesianas ",** sob a orientação do Prof. **Dr. Gilton José Ferreira da Silva.** A Sessão foi presidida pelo Prof. **Dr. Gilton José Ferreira da Silva** (PROCC/UFS), que após a apresentação da dissertação passou a palavra aos outros membros da Banca Examinadora, o **Dr. Allan Edgard Silva Freitas (IFBA)** e, em seguida, **Dr. Josielson Costa da Silva (UFBA) e Dr. Fábio Gomes Rocha (PROCC/ UFS)**. Após as discussões, a Banca Examinadora reuniu-se e considerou o mestrando (a) **APROVADO** . Atendidas as exigências da Instrução Normativa 05/2019/PROCC, do Regimento Interno do PROCC (Resolução 67/2014/CONEPE), e da Resolução n° 04/2021/CONEPE que regulamentam a Apresentação e Defesa de Dissertação, e nada mais havendo a tratar, a Banca Examinadora elaborou esta Ata que será assinada pelos seus membros e pelo mestrando.

Cidade Universitária "*Prof. José Aloísio de Campos*", 30 de julho de 2026.

gov.br Documento assinado digitalmente
GILTON JOSE FERREIRA DA SILVA
Data: 16/08/2026 18:10:56-0300
Verifique em https://validar.iti.gov.br

Prof. Dr. Gilton José Ferreira da Silva
(PROCC/UFS)
Presidente

gov.br Documento assinado digitalmente
FABIO GOMES ROCHA
Data: 17/08/2026 08:54:56-0300
Verifique em https://validar.iti.gov.br

Prof. Dr. Fabio Gomes Rocha
(PROCC/UFS)
Examinador Interno

gov.br Documento assinado digitalmente
ALLAN EDGARD SILVA FREITAS
Data: 16/08/2026 12:40:32-0300
Verifique em https://validar.iti.gov.br

Prof. Dr. Allan Edgard Silva Freitas
(IFBA)
Examinador Externo à Instituição

gov.br Documento assinado digitalmente
JOSIELSON COSTA DA SILVA
Data: 15/08/2026 23:40:47-0300
Verifique em https://validar.iti.gov.br

Prof. Dr. Josielson Costa da Silva
(UFBA)
Examinador Externo à Instituição

Jean Louis Silva Santos
Candidato

gov.br Documento assinado digitalmente
JEAN LOUIS SILVA SANTOS
Data: 10/08/2026 10:50:30-0300
Verifique em https://validar.iti.gov.br

Sumário

1 Introdução 22
1.1 Contextualização 23
1.2 Problema de Pesquisa 24
1.3 Hipótese de Pesquisa 25
1.4 Objetivos 26
1.4.1 Objetivo Geral 26
1.4.2 Objetivos Específicos 26
1.5 Justificativa 27
1.6 Contribuições da Pesquisa 28
1.7 Delimitação da Pesquisa 29
1.8 Organização da Dissertação 30

2 Fundamentação Teórica 31
2.1 Alta Segura do Recém-Nascido 31
2.1.1 Transição do Cuidado 32
2.1.2 Critérios Clínicos e Assistenciais 32
2.1.3 Desafios para Padronização 33
2.2 Inteligência Artificial Aplicada à Saúde 33
2.2.1 Sistemas de Apoio à Decisão Clínica 34
2.2.2 Limitações de Dados em Saúde 34
2.2.3 Cold Start em Saúde Digital 34
2.3 Dados Sintéticos em Saúde 35
2.3.1 Conceito e Tipos de Dados Sintéticos 35
2.3.2 Privacidade e Privacy-by-design 35
2.3.3 Utilidade e Plausibilidade Clínica 36
2.4 Redes Bayesianas 36
2.4.1 Estrutura e Inferência 36
2.4.2 Interpretabilidade 37
2.4.3 Redes Bayesianas como Geradores Sintéticos 37
2.5 Human-in-the-Loop e Modelagem Knowledge-driven 38
2.5.1 Modelagem Orientada por Conhecimento 38
2.5.2 Papel dos Especialistas 38
2.6 Seleção Incremental de Variáveis 38
2.6.1 Core11 39
2.6.2 Core18 39

2.6.3 Core25 como Horizonte Futuro . . . 39
2.7 Tabelas de Probabilidade Condicional . . . 40
2.7.1 Representação do Conhecimento . . . 40
2.7.2 Elicitação e Rastreabilidade . . . 40
2.8 Zeros Estruturais e Edit Checks Clínicos . . . 41
2.8.1 Zeros Estruturais . . . 41
2.8.2 Edit Checks Clínicos . . . 41
2.8.3 Plausibilidade Clínica Individual . . . 41
2.9 Maldição da Dimensionalidade . . . 42
2.9.1 Complexidade em Redes Bayesianas . . . 42
2.9.2 Expansão Incremental como Estratégia . . . 42
2.10 Síntese do Capítulo . . . 43

3 Metodologia . . . 44
3.1 Visão Geral da Metodologia . . . 44
3.2 Desenho da Pesquisa . . . 47
3.3 Construção da Base de Conhecimento . . . 48
3.3.1 Levantamento Bibliográfico e Rastreabilidade . . . 49
3.3.2 Participação Humana e Curadoria Clínica . . . 49
3.4 Seleção Incremental das Variáveis . . . 49
3.4.1 Core11 . . . 50
3.4.2 Core18 . . . 51
3.4.3 Core25 como Perspectiva Futura . . . 51
3.5 Modelagem Causal da Rede Bayesiana . . . 51
3.5.1 Definição da DAG . . . 52
3.5.2 Justificativas Clínicas das Arestas . . . 53
3.5.3 Auditoria de Consistência Estrutural . . . 53
3.5.4 Validação Clínica da Topologia . . . 53
3.6 Construção das Tabelas de Probabilidade Condicional . . . 54
3.6.1 Processo de Elicitação . . . 54
3.6.2 Parametrização . . . 54
3.6.3 Validação das CPTs . . . 55
3.6.4 Zeros Estruturais . . . 55
3.7 Construção dos Edit Checks . . . 55
3.7.1 Definição . . . 55
3.7.2 Validação Clínica e Papel Metodológico . . . 56
3.7.3 Integração com a Rede Bayesiana . . . 56
3.8 Implementação Computacional . . . 57
3.8.1 Arquitetura do Código . . . 57
3.8.2 Algoritmo de Geração . . . 57

3.8.3 Processo de Geração e Saída . . . 57
3.9 Sistema de Escore e Classificação da Decisão de Alta . . . 58
3.10 Estratégia de Validação . . . 59
3.10.1 Validação Estrutural . . . 61
3.10.2 Validação Estatística e Topológica . . . 61
3.10.3 Validação Preditiva e Explicativa . . . 61
3.10.4 Validação Clínica Interna . . . 61
3.11 Experimentos Realizados . . . 62
3.12 Comparação Metodológica Core11–Core18 . . . 62
3.13 Reprodutibilidade e Organização dos Artefatos . . . 63
3.14 Delimitações Metodológicas . . . 64
3.15 Síntese do Capítulo . . . 64

4 Trabalhos Relacionados . . . 65
4.1 Estratégia de Levantamento e Organização da Literatura . . . 65
4.1.1 Síntese do Levantamento . . . 69
4.2 Modelos de Inteligência Artificial em Neonatologia . . . 70
4.3 Geração de Dados Sintéticos em Saúde . . . 71
4.4 Redes Bayesianas e Modelagem Orientada por Conhecimento . . . 72
4.5 Validação de Dados Sintéticos na Ausência de Dados Reais . . . 73
4.6 Síntese Comparativa dos Trabalhos Relacionados . . . 74
4.7 Lacunas Identificadas . . . 82
4.8 Posicionamento da Proposta . . . 83

5 Resultados e Discussões . . . 85
5.1 Organização dos Resultados . . . 85
5.2 Resultados do Core11 . . . 86
5.2.1 Distribuição das Decisões no Core11 . . . 86
5.2.2 Protocolos de Validação no Core11 . . . 86
5.3 Resultados do Core18 . . . 87
5.3.1 Distribuição das Decisões no Core18 . . . 87
5.3.2 Fidelidade Estatística e Inferência Condicional . . . 89
5.3.3 Utilidade Preditiva Interna e Explicabilidade . . . 89
5.3.4 Validação dos Limiares e Casos-Limite . . . 91
5.3.5 Fidelidade Topológica Multivariada . . . 93
5.3.6 Auditoria por Edit Checks . . . 94
5.4 Comparação entre Core11 e Core18 . . . 96
5.5 Discussão Integrada dos Achados . . . 97
5.6 Ameaças à Validade . . . 97
5.6.1 Validade Interna . . . 98

5.6.2 Validade Externa . . . 99
5.6.3 Validade de Construto . . . 99
5.6.4 Validade de Conclusão . . . 100
5.7 Síntese do Capítulo . . . 100

6 Considerações Finais e Trabalhos Futuros . . . 102
6.1 Retomada dos Objetivos . . . 102
6.2 Principais Contribuições . . . 103
6.3 Síntese dos Achados . . . 103
6.4 Limitações . . . 104
6.5 Trabalhos Futuros . . . 105
6.6 Encerramento . . . 105

Referências . . . 107

Apêndices 112

APÊNDICE A Síntese das Tabelas de Probabilidade Condicional do Core18 . . . 113

APÊNDICE B Síntese da Matriz de Justificação das Arestas da Rede Bayesiana . 119

APÊNDICE C Síntese dos Edit Checks Clínicos do Core18 . . . 123

APÊNDICE D Rastreabilidade dos Artefatos Metodológicos . . . 127

Anexos 130

ANEXO A Parecer de Aprovação do Comitê de Ética em Pesquisa (CEP/EEUFBA nº 8.484.157) . . . 131

1 Introdução

A alta hospitalar do recém-nascido constitui uma etapa crítica da transição do cuidado, pois desloca a responsabilidade assistencial do ambiente hospitalar para o domicílio e exige que as condições clínicas, preventivas, familiares e de seguimento sejam adequadamente avaliadas. No contexto neonatal, essa transição é particularmente sensível, uma vez que alterações fisiológicas aparentemente discretas podem evoluir rapidamente para agravos relevantes, reinternações ou complicações evitáveis. Por essa razão, a alta segura demanda avaliação multidimensional, padronização de critérios e apoio à tomada de decisão profissional Sociedade Brasileira de Pediatria (2021), Brasil. Ministério da Saúde (2016), Silva et al. (2024a).

Sistemas de apoio à decisão clínica baseados em Inteligência Artificial (IA) têm sido investigados como instrumentos capazes de reduzir a variabilidade, organizar múltiplas fontes de informação e apoiar a estratificação de risco em saúde Chen et al. (2021), Kwok et al. (2022). Na neonatologia, modelos preditivos vêm sendo aplicados principalmente à mortalidade, às morbidades críticas, à sepse neonatal e à identificação precoce de risco, demonstrando potencial para apoiar decisões em cenários complexos Batista et al. (2021), Kwok et al. (2022), Bernardino et al. (2024). Entretanto, a construção desses modelos depende, em geral, de bases de dados clínicas extensas, rotuladas e representativas, o que frequentemente não está disponível em instituições de saúde, sobretudo nas fases iniciais de desenvolvimento de soluções computacionais.

Esse cenário caracteriza o problema de *cold start*: a necessidade de desenvolver, testar e validar modelos computacionais em domínios nos quais ainda não existem dados reais suficientes, acessíveis ou adequadamente rotulados. Em saúde, essa dificuldade é ampliada por restrições éticas, legais e regulatórias relacionadas ao uso de dados sensíveis, incluindo a Lei Geral de Proteção de Dados (LGPD) e normas internacionais de proteção de privacidade Nisevic, Milojevic e Spajic (2025), Rajotte et al. (2022). Assim, mesmo quando registros clínicos existem, seu compartilhamento e uso secundário para pesquisa ou desenvolvimento tecnológico podem ser limitados.

A geração de dados sintéticos surge como alternativa para mitigar parte dessas barreiras. Dados totalmente sintéticos podem permitir o desenvolvimento, teste e auditoria de modelos computacionais sem exposição direta de prontuários reais, contribuindo para estratégias de *privacy-by-design* Goncalves et al. (2020), Jordon et al. (2022). Contudo, grande parte das abordagens de síntese em saúde é orientada a dados, exigindo bases reais como insumo inicial de treinamento. Além disso, modelos puramente *data-driven* podem reproduzir vieses, memorizar padrões sensíveis ou gerar combinações clinicamente implausíveis quando não incorporam restrições explícitas de domínio Murtaza et al. (2023), Kaabachi et al. (2025).

Diante dessas limitações, esta dissertação propõe uma abordagem *knowledge-driven* para geração de dados totalmente sintéticos no contexto da alta segura neonatal. Em vez de aprender diretamente a partir de prontuários reais, o modelo é construído com base em conhecimento clínico, literatura especializada, documentos normativos e curadoria humana. A solução utiliza Redes Bayesianas para representar dependências probabilísticas entre variáveis neonatais, Tabelas de Probabilidade Condicional (CPTs) para parametrizar essas relações, e mecanismos de auditoria clínica para avaliar a plausibilidade dos registros gerados Kaur et al. (2021), Flores et al. (2023), Santos, Silva e Silva (2026).

A proposta foi desenvolvida de forma incremental. Inicialmente, foi estruturado um modelo com 11 variáveis clínicas, denominado Core11, utilizado como prova inicial da arquitetura. Em seguida, a metodologia foi expandida para um modelo com 18 variáveis, denominado Core18, que constitui a principal contribuição experimental desta dissertação. A expansão para versões mais amplas, como Core25, é reconhecida como continuidade natural do trabalho, mas não integra o escopo experimental validado nesta dissertação.

Importa destacar que esta pesquisa não tem como objetivo validar um sistema assistencial para uso direto em pacientes. O estudo é metodológico-computacional, conduzido em ambiente de simulação, sem implantação hospitalar, sem integração com prontuário eletrônico e sem comparação prospectiva com decisões clínicas reais. Sua contribuição reside na construção e avaliação de um pipeline auditável para modelar, gerar, validar e identificar limites de dados sintéticos neonatais em cenário de ausência de dados reais.

1.1 Contextualização

A alta segura neonatal envolve a verificação de múltiplas dimensões: estabilidade biofisiológica, alimentação, sinais vitais, triagens neonatais, vacinação, preparo familiar, condições de seguimento e articulação com a rede de atenção. Esse conjunto de fatores reforça que a decisão de alta não pode ser reduzida a um único marcador clínico, mas deve resultar da integração de informações heterogêneas e interdependentes Araujo et al. (2023), Sociedade Brasileira de Pediatria (2020), Sociedade Brasileira de Pediatria (2021), Brasil. Ministério da Saúde (2014), World Health Organization (2022), Silva et al. (2024a).

No campo da Inteligência Artificial aplicada à saúde, essa multidimensionalidade representa uma oportunidade e, simultaneamente, uma dificuldade. Modelos computacionais podem apoiar a análise de padrões complexos, mas dependem de dados de qualidade para treinamento, avaliação e calibração. Em neonatologia, bases clínicas podem ser fragmentadas, incompletas, institucionalmente restritas ou insuficientemente rotuladas para determinados desfechos. Além disso, a proteção da privacidade impõe limites legítimos ao uso secundário de informações sensíveis Chen et al. (2021), Nisevic, Milojevic e Spajic (2025).

A literatura sobre dados sintéticos em saúde aponta que a síntese de dados pode contribuir para pesquisa, desenvolvimento de algoritmos e simulação de cenários sem expor diretamente indivíduos reais Goncalves et al. (2020), Murtaza et al. (2023). Entretanto, quando a síntese é baseada em dados reais, permanecem desafios associados à disponibilidade inicial da base, ao risco residual de memorização e à preservação de coerência clínica. Em domínios críticos, como a neonatologia, não basta que a base sintética apresente distribuições estatísticas plausíveis; é necessário que as combinações geradas sejam interpretáveis, auditáveis e compatíveis com o conhecimento clínico.

Nesse contexto, Redes Bayesianas oferecem uma alternativa metodológica relevante, pois permitem representar relações condicionais entre variáveis de forma explícita, interpretável e compatível com conhecimento de especialistas Kaur et al. (2021), Flores et al. (2023). Ao estruturar a rede por conhecimento clínico, e não por aprendizado automático sobre prontuários reais, torna-se possível construir um gerador sintético orientado por hipóteses causais, probabilidades elicitadas e regras de auditoria.

A presente dissertação situa-se nessa interseção entre alta segura neonatal, dados sintéticos, Redes Bayesianas e privacidade. O trabalho busca responder a um problema prático e científico: como construir dados sintéticos úteis para pesquisa e desenvolvimento em um domínio sensível, sem depender de registros reais prévios, e mantendo rastreabilidade suficiente para que a estrutura do modelo possa ser auditada.

1.2 Problema de Pesquisa

O desenvolvimento de sistemas de apoio à decisão clínica em neonatologia enfrenta uma tensão metodológica relevante. Por um lado, há necessidade de modelos capazes de lidar com múltiplas variáveis clínicas e apoiar decisões complexas, como a alta hospitalar do recém-nascido. Por outro, a construção desses modelos é limitada pela escassez de dados rotulados, pela fragmentação dos registros e pelas restrições ético-legais ao uso de informações sensíveis Chen et al. (2021), Nisevic, Milojevic e Spajic (2025).

Abordagens tradicionais de geração de dados sintéticos, especialmente as orientadas a dados, podem aliviar parte desse problema, mas não resolvem completamente o *cold start*. Isso ocorre porque tais métodos ainda necessitam de uma base real inicial para aprendizado.

Além disso, em saúde, a reprodução de correlações estatísticas sem incorporação explícita de conhecimento de domínio pode produzir registros sintéticos com combinações biologicamente improváveis ou clinicamente pouco defensáveis Goncalves et al. (2020), Murtaza et al. (2023).

No caso da alta neonatal, esse desafio é ampliado pela natureza multidimensional do fenômeno. A decisão de alta depende de variáveis interdependentes, como idade gestacional, peso ao nascer, estabilidade respiratória, alimentação, sinais de alerta, triagens, vacinação e outros indicadores de prontidão clínica. A modelagem dessas relações exige não apenas representação estatística, mas também rastreabilidade, justificativa clínica das dependências e mecanismos de auditoria.

Dessa forma, a lacuna investigada por esta dissertação pode ser sintetizada na seguinte questão de pesquisa:

> Como modelar, gerar e validar dados totalmente sintéticos para o contexto da alta segura neonatal, por meio de uma metodologia orientada por conhecimento, baseada em Redes Bayesianas e curadoria clínica, sem depender de prontuários reais prévios e preservando propriedades probabilísticas, topológicas e de plausibilidade clínica auditável?

Essa pergunta explicita duas dimensões do problema. A primeira é a construção do gerador sintético em cenário de ausência de dados reais. A segunda é a necessidade de validar criticamente os dados produzidos, reconhecendo que coerência estatística global não implica, necessariamente, plausibilidade clínica individual plena.

1.3 Hipótese de Pesquisa

A hipótese central desta dissertação é que uma metodologia *knowledge-driven*, baseada em Redes Bayesianas, CPTs, curadoria clínica e regras de auditoria, é capaz de gerar dados totalmente sintéticos para a alta neonatal com preservação de propriedades probabilísticas e topológicas relevantes, mesmo na ausência de prontuários reais para treinamento.

Essa hipótese não pressupõe que todos os registros sintéticos gerados sejam clinicamente perfeitos ou plenamente plausíveis linha a linha. Ao contrário, parte-se do entendimento de que a validade de uma base sintética em saúde deve ser examinada em múltiplas camadas: fidelidade estatística, coerência de inferência condicional, preservação da estrutura multivariada, utilidade preditiva interna, explicabilidade e auditoria clínica de combinações individuais.

Assim, a hipótese operacional deste trabalho pode ser formulada da seguinte maneira: se o conhecimento clínico normativo for representado em uma Rede Bayesiana por meio de topologia causal, CPTs e regras de auditoria, então será possível gerar coortes sintéticas neonatais úteis para avaliação metodológica e desenvolvimento computacional, preservando padrões probabilísticos

definidos pelo modelo e evidenciando, de forma auditável, seus próprios limites de plausibilidade clínica.

Essa formulação é deliberadamente cautelosa. O objetivo não é afirmar validade assistencial direta, mas avaliar se a metodologia produz uma base sintética internamente consistente, interpretável e suficientemente estruturada para apoiar pesquisa, simulação e desenvolvimento futuro de sistemas de apoio à decisão.

1.4 Objetivos

Esta seção apresenta o objetivo geral e os objetivos específicos que orientam o desenvolvimento da dissertação.

1.4.1 Objetivo Geral

O objetivo geral desta dissertação é desenvolver e avaliar uma metodologia *knowledge-driven*, baseada em Redes Bayesianas, para a geração de dados totalmente sintéticos aplicados ao contexto da alta segura neonatal, em ambiente de simulação, sem uso de prontuários reais no processo de modelagem, e com validação multidimensional de fidelidade probabilística, estrutura topológica, utilidade preditiva interna e plausibilidade clínica auditável.

1.4.2 Objetivos Específicos

Para alcançar o objetivo geral, foram definidos os seguintes objetivos específicos:

1. Selecionar e organizar, de forma incremental, variáveis clínicas relevantes para a alta segura neonatal, estruturando os modelos Core11 e Core18 a partir de referencial normativo, literatura especializada e curadoria de conhecimento clínico.

2. Modelar a topologia da Rede Bayesiana por meio de um Grafo Direcionado Acíclico (DAG), representando dependências condicionais entre variáveis neonatais de forma interpretável e rastreável.

3. Parametrizar as Tabelas de Probabilidade Condicional (CPTs) a partir de conhecimento clínico, literatura e decisões metodológicas documentadas, garantindo fechamento probabilístico e coerência interna das distribuições implementadas.

4. Implementar mecanismos de escore e classificação da decisão de alta, derivando a variável de desfecho sintética a partir de regras normativas e pesos definidos para as variáveis clínicas.

5. Diferenciar zeros estruturais incorporados ao processo de amostragem de edit checks clínicos aplicados como auditoria pós-geração, registrando o papel de cada mecanismo na avaliação da plausibilidade dos dados sintéticos.

6. Desenvolver e aplicar protocolos de validação interna para avaliar fidelidade estatística, inferência condicional, utilidade preditiva em regime *Train on Synthetic, Test on Synthetic* (TSTS), explicabilidade, sensibilidade de limiares, casos-limite e fidelidade topológica multivariada.

7. Analisar criticamente os resultados obtidos nos modelos Core11 e Core18, identificando tanto evidências de preservação probabilística e topológica quanto limitações relacionadas à plausibilidade clínica individual e aos limiares normativos.

1.5 Justificativa

A relevância desta pesquisa decorre da necessidade de conciliar a inovação em Inteligência Artificial na saúde, a proteção de dados sensíveis e a segurança na transição do cuidado neonatal. A alta hospitalar do recém-nascido é um processo de alta responsabilidade clínica, no qual decisões inadequadas podem aumentar riscos de reinternação, complicações evitáveis e sobrecarga da rede de atenção Sociedade Brasileira de Pediatria (2020), Sociedade Brasileira de Pediatria (2021), Brasil. Ministério da Saúde (2016), Instituto Nacional de Saúde da Mulher, da Criança e do Adolescente Fernandes Figueira (2020), Araujo et al. (2023), Silva et al. (2024a).

Do ponto de vista tecnológico, o avanço de sistemas de apoio à decisão clínica depende de dados adequados para desenvolvimento, teste e validação. Entretanto, em muitos cenários reais, especialmente em fases iniciais de pesquisa, não há disponibilidade de bases clínicas suficientemente completas, rotuladas e acessíveis. Mesmo quando existem, restrições de privacidade limitam seu compartilhamento e uso secundário Nisevic, Milojevic e Spajic (2025), Rajotte et al. (2022). Nesse contexto, uma metodologia capaz de gerar dados totalmente sintéticos sem consumir prontuários reais oferece uma alternativa relevante para contornar o *cold start*.

Do ponto de vista científico, a pesquisa se justifica por explorar uma via diferente das abordagens predominantemente *data-driven*. Ao estruturar a geração sintética a partir de conhecimento clínico e Redes Bayesianas, o trabalho valoriza a interpretabilidade, a rastreabilidade e a auditabilidade. Essas características são particularmente importantes em saúde, onde a utilidade de um modelo não depende apenas de desempenho computacional, mas também da capacidade de explicar suas premissas, dependências e limitações Kaur et al. (2021), Flores et al. (2023), Santos, Silva e Silva (2026).

Do ponto de vista metodológico, a dissertação contribui ao reconhecer que dados sintéticos em saúde devem ser avaliados por múltiplas dimensões. Uma base pode preservar distribuições marginais e relações agregadas, mas ainda conter combinações individuais clinica-

mente discutíveis. Por isso, a proposta incorpora protocolos de fidelidade estatística, inferência condicional, utilidade preditiva interna, fidelidade topológica e edit checks clínicos como auditoria de plausibilidade, em diálogo com a literatura recente sobre avaliação de fidelidade, utilidade e privacidade em dados sintéticos tabulares Emam et al. (2022), Boni, Junior e Costa (2025), Alaa et al. (2022).

Assim, a justificativa central deste trabalho não está apenas na geração de uma base sintética neonatal, mas na construção de um processo auditável para gerar, avaliar e discutir criticamente essa base. Essa postura é relevante porque permite que resultados positivos e negativos sejam interpretados como evidências metodológicas, orientando melhorias futuras no modelo.

1.6 Contribuições da Pesquisa

A principal contribuição desta dissertação é a proposição de um pipeline *knowledge-driven* para geração e validação de dados totalmente sintéticos no contexto da alta segura neonatal. Esse pipeline integra seleção incremental de variáveis, modelagem por Rede Bayesiana, parametrização de CPTs, geração de registros sintéticos, cálculo de escore, classificação de decisão de alta e protocolos complementares de validação.

A segunda contribuição consiste na demonstração incremental da metodologia por meio dos modelos Core11 e Core18. O Core11 funciona como prova inicial da arquitetura, enquanto o Core18 amplia o domínio clínico e permite avaliar a capacidade de expansão da proposta diante de maior complexidade topológica e um maior número de variáveis.

A terceira contribuição é a explicitação da diferença entre coerência probabilística agregada e plausibilidade clínica individual. Ao incorporar edit checks como auditoria pós-geração no Core18, a dissertação mostra que um gerador pode preservar propriedades estatísticas e topológicas relevantes e, ainda assim, produzir registros individuais que exigem cautela interpretativa. Essa constatação é importante para o uso responsável de dados sintéticos em saúde.

A quarta contribuição é a organização de um framework de validação interna aplicável a cenários sem dados reais de referência. Como o estudo não dispõe de uma base real para TSTR, a validação é estruturada em torno de métricas internas e auditáveis, incluindo TSTS, Distância de Hellinger, PCD, análise de limiares, explicabilidade e auditoria clínica. Essa estratégia não substitui a validação externa futura, mas oferece um caminho metodológico para cenários de *cold start*.

Por fim, a dissertação contribui para o debate sobre *privacy-by-design* em saúde ao propor uma abordagem que não utiliza prontuários reais para construir o gerador. Com isso, desloca-se o foco da anonimização de registros existentes para a modelagem explícita de conhecimento

clínico, mantendo a privacidade como princípio estrutural da arquitetura.

1.7 Delimitação da Pesquisa

A delimitação do escopo é fundamental para interpretar adequadamente os resultados desta dissertação. Este trabalho não pretende esgotar o problema da alta segura neonatal nem substituir julgamento profissional. Seu foco é metodológico e computacional.

1. **Formato dos dados**: a pesquisa restringe-se à geração de dados tabulares sintéticos. Não são abordadas séries temporais de monitores, imagens médicas, sinais fisiológicos contínuos ou texto livre de prontuários Hernandez et al. (2022), Murtaza et al. (2023), Miletic e Sariyar (2026), Neves, Junior e Franco (2026).

2. **Origem do aprendizado**: o modelo é orientado por conhecimento e não aprende diretamente a partir de prontuários reais. A estrutura e os parâmetros são definidos por literatura, documentos normativos, curadoria clínica e decisões metodológicas registradas Santos, Silva e Silva (2026).

3. **Escopo experimental**: a contribuição experimental encerra-se no Core18. O Core11 é tratado como prova inicial da arquitetura e o Core18 como versão expandida principal. O Core25 é reconhecido como trabalho futuro.

4. **Domínio clínico**: o foco está na alta segura neonatal e na geração de perfis sintéticos relacionados à prontidão para desospitalização. A pesquisa não modela todas as condições clínicas possíveis de uma Unidade de Terapia Intensiva Neonatal.

5. **Validação**: a validação ocorre em ambiente de simulação e utiliza protocolos internos. Não há TSTR, validação prospectiva, comparação com decisões clínicas reais ou avaliação de impacto assistencial.

6. **Uso clínico**: o modelo não é apresentado como sistema para diagnóstico, prescrição, triagem operacional ou tomada de decisão clínica direta. Os resultados devem ser interpretados como contribuição metodológica para pesquisa e desenvolvimento.

7. **Edit checks**: no Core18, os edit checks são empregados como auditoria pós-geração. Eles identificam violações e limites de plausibilidade clínica, mas não filtram automaticamente registros nem executam reamostragem condicionada.

Essas delimitações preservam a coerência do estudo e evitam extrapolações indevidas. A dissertação avalia a viabilidade e os limites de uma metodologia de geração sintética, não a efetividade assistencial de um sistema clínico em produção.

1.8 Organização da Dissertação

A dissertação está organizada em seis capítulos.

1. O Capítulo 1 apresenta a introdução, contextualizando o problema da alta segura neonatal, o desafio do *cold start*, a motivação para uso de dados sintéticos e a proposta *knowledge-driven*. Também define problema de pesquisa, hipótese, objetivos, justificativa, contribuições e delimitações.

2. O Capítulo 2 apresenta a fundamentação teórica e clínica, abordando alta segura neonatal, Inteligência Artificial aplicada à saúde, dados sintéticos, Redes Bayesianas, Human-in-the-Loop, Core Outcome Sets, CPTs, edit checks e maldição da dimensionalidade.

3. O Capítulo 3 discute trabalhos relacionados, posicionando a pesquisa frente a modelos preditivos em neonatologia, métodos de síntese de dados tabulares em saúde e abordagens de privacidade.

4. O Capítulo 4 descreve a metodologia adotada, incluindo desenho da pesquisa, construção da base de conhecimento, seleção incremental das variáveis, modelagem causal da Rede Bayesiana, construção das CPTs, implementação computacional, sistema de escore, protocolos de validação, experimentos Core11 e Core18 e delimitações metodológicas.

5. O Capítulo 5 apresenta os resultados e discussões, comparando Core11 e Core18, analisando métricas de validação, discutindo achados favoráveis e limitações, e interpretando os efeitos da expansão do modelo sobre a coerência probabilística, topológica e clínica.

6. O Capítulo 6 reúne as considerações finais, retomando problema, hipótese e objetivos, sintetizando as contribuições da pesquisa, explicitando limitações e indicando trabalhos futuros, incluindo calibração com especialistas, filtragem clínica, reamostragem condicionada, validação externa e expansão para Core25.

2

Fundamentação Teórica

Este capítulo apresenta os fundamentos clínicos, conceituais e computacionais que sustentam a metodologia proposta nesta dissertação. O objetivo é construir uma base teórica suficiente para compreender a alta segura neonatal como problema multidimensional, a limitação do uso de dados reais em saúde, o papel dos dados sintéticos em cenários de *cold start* e a escolha das Redes Bayesianas como formalismo interpretável para geração de dados orientada por conhecimento Araujo et al. (2023), Queiroz et al. (2019), Silva et al. (2024a), Goncalves et al. (2020), Kaur et al. (2021).

A organização do capítulo segue a lógica do próprio problema de pesquisa. Inicialmente, discutem-se a alta segura do recém-nascido e a transição do cuidado, situando o domínio clínico da aplicação. Em seguida, aborda-se a Inteligência Artificial aplicada à saúde e à neonatologia, com atenção às barreiras de dados e privacidade. Posteriormente, apresentam-se os conceitos de dados sintéticos, Redes Bayesianas, abordagem *Human-in-the-Loop*, seleção incremental de variáveis, CPTs, zeros estruturais, *edit checks* e maldição da dimensionalidade, conceitos recorrentes na literatura de dados sintéticos em saúde, modelagem probabilística e apoio à decisão clínica Chen et al. (2021), Goncalves et al. (2020), Murtaza et al. (2023), Flores et al. (2023), Santos, Silva e Silva (2026).

2.1 Alta Segura do Recém-Nascido

A alta segura neonatal é um processo clínico e assistencial que envolve a avaliação da prontidão do recém-nascido e da família para a transição do ambiente hospitalar ao domicílio. Trata-se de uma decisão complexa, pois envolve não apenas a estabilidade clínica imediata, mas também a capacidade de alimentação, a realização de triagens e imunizações, a identificação de sinais de alerta, o preparo familiar e a continuidade do cuidado na rede de atenção Sociedade Brasileira de Pediatria (2020), Sociedade Brasileira de Pediatria (2021), Sociedade Brasileira de

Pediatria (2018), Brasil. Ministério da Saúde (2016), Araujo et al. (2023), Queiroz et al. (2019), Silva et al. (2024a).

2.1.1 Transição do Cuidado

A alta hospitalar pode ser compreendida como uma transição de cuidado, na qual a responsabilidade assistencial passa progressivamente da equipe hospitalar para a família e para os serviços de acompanhamento pós-alta. No período neonatal, essa transição é particularmente sensível, pois o recém-nascido ainda se encontra em adaptação fisiológica à vida extrauterina e pode apresentar alterações de evolução rápida, como dificuldades alimentares, perda ponderal excessiva, icterícia, instabilidade térmica ou sinais respiratórios Araujo et al. (2023), Queiroz et al. (2019), Sociedade Brasileira de Pediatria (2021), World Health Organization (2022).

Do ponto de vista assistencial, a alta segura exige que a decisão de desospitalização seja apoiada por critérios mínimos de prontidão. Esses critérios não devem ser avaliados de forma isolada, pois a segurança do recém-nascido resulta da combinação entre estabilidade biofisiológica, preparo dos cuidadores e garantia de seguimento. Assim, a alta neonatal deve ser compreendida como um fenômeno multidimensional, e não como um ato administrativo de encerramento da internação Brasil. Ministério da Saúde (2015), Instituto Nacional de Saúde da Mulher, da Criança e do Adolescente Fernandes Figueira (2020), Silva et al. (2024a), Silva et al. (2024b).

2.1.2 Critérios Clínicos e Assistenciais

As diretrizes clínicas apontam que a alta do recém-nascido deve considerar parâmetros biofisiológicos, preventivos e familiares. Entre os critérios biofisiológicos, destacam-se estabilidade respiratória, frequência cardíaca adequada, normotermia, ausência de sinais relevantes de desconforto, exame físico compatível com a alta, alimentação eficaz e eliminações fisiológicas adequadas Sociedade Brasileira de Pediatria (2021), Brasil. Ministério da Saúde (2014), Brasil. Ministério da Saúde (2012), Araujo et al. (2023), Organização Pan-Americana da Saúde e Brasil. Ministério da Saúde (2014).

A estabilidade térmica merece atenção particular, pois a hipotermia neonatal é evento prevenível e associado a maior vulnerabilidade clínica, especialmente em recém-nascidos prematuros ou de baixo peso. A literatura sobre contato pele a pele e hipotermia neonatal reforça a relevância de variáveis relacionadas a temperatura, adaptação fisiológica e cuidado térmico no período pós-natal Beiranvand et al. (2014), Beletew et al. (2020).

No eixo preventivo, a realização de triagens neonatais e a adequada programação vacinal constituem elementos importantes da segurança pós-alta. Esses componentes são especialmente relevantes porque a alta não deve romper a continuidade assistencial, mas articular o cuidado hospitalar com a Atenção Primária e com os serviços de seguimento. A primeira consulta pós-alta,

a orientação aos cuidadores e a identificação precoce de sinais de alerta são elementos essenciais para reduzir riscos no domicílio Sociedade Brasileira de Pediatria (2021), Brasil. Ministério da Saúde (2015), World Health Organization (2022), Silva et al. (2024a).

Além disso, a preparação da família deve incluir orientações sobre aleitamento, higiene, coto umbilical, sono seguro, sinais de perigo e busca oportuna por atendimento. A literatura enfatiza que limitações de comunicação, ansiedade materna, baixa escolaridade, barreiras socioeconômicas e fragmentação da rede de saúde podem comprometer a efetividade da alta, mesmo quando o recém-nascido apresenta estabilidade clínica inicial Araujo et al. (2023), Instituto Nacional de Saúde da Mulher, da Criança e do Adolescente Fernandes Figueira (2020), Lucchese et al. (2024), Silva et al. (2024b).

2.1.3 Desafios para Padronização

Apesar da existência de diretrizes, a decisão de alta neonatal ainda pode variar conforme instituição, equipe, disponibilidade de informações e experiência profissional. Essa variabilidade é um dos motivos para o desenvolvimento de instrumentos estruturados, checklists, aplicativos de apoio à orientação e sistemas de apoio à decisão, capazes de organizar critérios mínimos de prontidão e reduzir lacunas na transição do cuidado Sociedade Brasileira de Pediatria (2020), Araujo et al. (2023), Lucchese et al. (2024), Silva et al. (2024a).

Esse cenário justifica a busca por modelos capazes de representar dependências entre variáveis clínicas e assistenciais. A alta segura não depende apenas de uma frequência cardíaca normal, de um peso adequado ou de uma triagem realizada, mas da coerência entre múltiplos fatores, incluindo estabilidade biofisiológica, preparo familiar e continuidade do cuidado Araujo et al. (2023), Sociedade Brasileira de Pediatria (2021), Silva et al. (2024a). Essa característica torna o domínio adequado para abordagens probabilísticas interpretáveis e auditáveis, como Redes Bayesianas orientadas por conhecimento Kaur et al. (2021), Flores et al. (2023), Santos, Silva e Silva (2026).

2.2 Inteligência Artificial Aplicada à Saúde

A Inteligência Artificial (IA) tem ampliado sua presença na saúde por meio de aplicações em predição de risco, apoio diagnóstico, priorização de pacientes, gestão de recursos e suporte à decisão clínica Chen et al. (2021), Kwok et al. (2022). Em termos gerais, esses sistemas buscam processar múltiplas variáveis e identificar padrões que possam auxiliar profissionais de saúde em decisões complexas.

2.2.1 Sistemas de Apoio à Decisão Clínica

Sistemas de Apoio à Decisão Clínica (SADC) são ferramentas computacionais que organizam dados, regras ou modelos preditivos para apoiar decisões profissionais. Em saúde, esses sistemas não devem substituir o julgamento clínico, mas oferecer informações estruturadas, alertas, estimativas de risco ou recomendações baseadas em critérios previamente definidos Chen et al. (2021), Kwok et al. (2022).

No contexto neonatal, a IA tem sido aplicada à predição de mortalidade, morbidades, risco de sepse, necessidade de intervenção e estratificação de risco em unidades neonatais Kwok et al. (2022), Batista et al. (2021), Bernardino et al. (2024). Esses avanços indicam potencial para apoiar decisões relacionadas à alta, desde que os modelos sejam desenvolvidos com dados adequados, validação rigorosa e interpretação compatível com o domínio clínico.

2.2.2 Limitações de Dados em Saúde

O desenvolvimento de modelos de IA depende de bases de dados representativas, consistentes e suficientemente rotuladas. Em neonatologia, porém, os registros podem ser fragmentados, incompletos ou heterogêneos entre instituições. Além disso, alguns desfechos são raros, dificultando o treinamento de modelos supervisionados robustos Chen et al. (2021), Batista et al. (2021), Kwok et al. (2022).

Outro desafio é regulatório e ético. Dados clínicos são sensíveis e estão sujeitos a normas de proteção de privacidade, como a LGPD e regulamentações internacionais. Mesmo quando bases existem, seu compartilhamento para pesquisa pode ser limitado por restrições institucionais, legais ou de governança, além de exigir atenção a vieses, representatividade e equidade em sistemas de IA aplicados à saúde Norori et al. (2021), Nisevic, Milojevic e Spajic (2025), Rajotte et al. (2022). Esse cenário cria barreiras para pesquisas em IA e caracteriza, em muitos projetos, o problema de *cold start*.

2.2.3 Cold Start em Saúde Digital

O *cold start* ocorre quando se deseja desenvolver ou testar uma solução computacional, mas ainda não há dados reais suficientes ou disponíveis para treinar e validar os modelos. Em saúde, essa situação é frequente em instituições menores, domínios altamente especializados ou fases iniciais de inovação, sendo agravada por restrições de privacidade, governança de dados sensíveis e baixa disponibilidade de bases rotuladas Chen et al. (2021), Goncalves et al. (2020), Nisevic, Milojevic e Spajic (2025).

No contexto desta dissertação, o *cold start* não é apenas uma limitação operacional, mas parte central do problema científico. A proposta busca investigar se é possível estruturar um gerador de dados totalmente sintéticos a partir de conhecimento clínico, sem depender de prontuários reais no processo de modelagem, em consonância com estratégias de geração sintética

e *privacy-by-design* discutidas na literatura Goncalves et al. (2020), Murtaza et al. (2023), Santos, Silva e Silva (2026).

2.3 Dados Sintéticos em Saúde

Dados sintéticos são dados gerados artificialmente por algoritmos ou modelos computacionais. Em saúde, eles podem ser utilizados para simulação, desenvolvimento de sistemas, treinamento de algoritmos, ensino, testes de software e pesquisa metodológica, reduzindo a exposição direta de dados sensíveis Goncalves et al. (2020), Hernandez et al. (2022), Jordon et al. (2022), Murtaza et al. (2023).

2.3.1 Conceito e Tipos de Dados Sintéticos

A literatura distingue diferentes níveis de síntese. Dados parcialmente sintéticos preservam parte dos registros reais e substituem apenas algumas variáveis sensíveis. Dados híbridos combinam componentes reais e artificiais. Dados totalmente sintéticos, por sua vez, são gerados sem copiar registros individuais, buscando representar padrões ou estruturas de interesse por meio de um modelo gerador Goncalves et al. (2020), Hernandez et al. (2022), Jordon et al. (2022), Boni, Junior e Costa (2025).

Esta dissertação adota a noção de dados totalmente sintéticos. A proposta não transforma prontuários reais nem aprende diretamente a partir de registros de pacientes. Em vez disso, gera perfis neonatais artificiais a partir de uma estrutura probabilística construída por conhecimento clínico, estratégia compatível com abordagens orientadas por conhecimento e com a necessidade de reduzir dependência de bases reais em cenários sensíveis Goncalves et al. (2020), Kaur et al. (2021), Santos, Silva e Silva (2026).

2.3.2 Privacidade e Privacy-by-design

O uso de dados sintéticos é frequentemente associado à preservação de privacidade. Entretanto, nem todo dado sintético é automaticamente seguro. Quando geradores são treinados em bases reais, pode haver risco residual de memorização, inferência de pertinência ou reidentificação, sobretudo quando o modelo reproduz padrões muito próximos dos registros originais Tucker et al. (2020), Yale et al. (2020), Giuffrè e Shung (2023), Murtaza et al. (2023), Nisevic, Milojevic e Spajic (2025), Kaabachi et al. (2025).

Por essa razão, a noção de *privacy-by-design* deve ser interpretada com cautela. No escopo desta dissertação, ela se justifica porque o gerador proposto não consome prontuários reais para definir sua estrutura ou seus parâmetros. A privacidade decorre da própria arquitetura de modelagem orientada por conhecimento, e não de um procedimento posterior de anonimização

ou desidentificação de dados sensíveis Tucker et al. (2020), Rajotte et al. (2022), Murtaza et al. (2023).

2.3.3 Utilidade e Plausibilidade Clínica

A literatura recente demonstra que a avaliação de qualidade de dados sintéticos tabulares na saúde não pode depender de uma única métrica, exigindo um framework multidimensional que analise simultaneamente os eixos de fidelidade estatística, utilidade preditiva e privacidade Hernandez et al. (2025), Boni, Junior e Costa (2025). Ao focar exclusivamente na utilidade, negligenciam-se os riscos de reidentificação ou o realismo clínico das amostras Kaabachi et al. (2025).

Essa distinção é central para a dissertação. O objetivo não é afirmar que todo registro sintético gerado é equivalente a um paciente real, mas avaliar se a coorte sintética preserva propriedades probabilísticas e topológicas relevantes e em quais condições surgem limites de plausibilidade individual, seguindo a recomendação de que dados sintéticos em saúde sejam avaliados por fidelidade, utilidade, privacidade e risco de inconsistência clínica Goncalves et al. (2020), Emam et al. (2022), Hernandez et al. (2025), Alaa et al. (2022).

Na literatura recente sobre dados sintéticos tabulares, observa-se também a busca por métricas mais abrangentes e menos dependentes de uma única dimensão. Propostas como métricas de fidelidade em nível amostral, índices agregados para dados tabulares e estruturas multidimensionais de avaliação reforçam que qualidade sintética envolve simultaneamente distribuição, diversidade, utilidade preditiva, privacidade e adequação ao uso pretendido Alaa et al. (2022), Chundawat et al. (2022), Boni, Junior e Costa (2025), Hernandez et al. (2025). Para esta dissertação, esse debate justifica a adoção de protocolos complementares, em vez de uma única métrica global.

2.4 Redes Bayesianas

Redes Bayesianas são modelos gráficos probabilísticos que representam variáveis aleatórias e suas dependências condicionais por meio de um Grafo Direcionado Acíclico (DAG). Cada nó representa uma variável, cada aresta indica uma relação de dependência e cada variável possui uma distribuição de probabilidade, que pode ser marginal ou condicionada aos seus pais Kaur et al. (2021), Castro e Santos (2023).

2.4.1 Estrutura e Inferência

A estrutura qualitativa de uma Rede Bayesiana é definida pelo DAG. Esse grafo permite representar hipóteses de dependência entre variáveis de forma visual e interpretável. A estrutura

quantitativa, por sua vez, é definida por distribuições de probabilidade, geralmente organizadas em Tabelas de Probabilidade Condicional (CPTs) Kaur et al. (2021), Castro e Santos (2023).

Uma propriedade importante das Redes Bayesianas é a possibilidade de realizar inferência probabilística. Dada uma evidência observada, o modelo pode atualizar probabilidades de outros nós, permitindo responder a perguntas condicionais. Essa característica é útil em domínios clínicos, nos quais decisões frequentemente precisam lidar com incerteza e informação incompleta Kaur et al. (2021), Flores et al. (2023).

2.4.2 Interpretabilidade

Em saúde, interpretabilidade é uma exigência metodológica relevante. Modelos de alta performance, mas pouco transparentes, podem ser difíceis de auditar clinicamente. Redes Bayesianas oferecem uma vantagem nesse aspecto porque tornam explícitas as variáveis consideradas, as relações condicionais assumidas e as probabilidades utilizadas Kaur et al. (2021), Flores et al. (2023).

Essa transparência permite que especialistas avaliem a plausibilidade das relações modeladas. Em uma aplicação neonatal, por exemplo, é possível discutir se a idade gestacional deve condicionar peso ao nascer, padrão respiratório, temperatura ou triagens. Essa discussão é mais difícil em modelos puramente *black-box*, nos quais a estrutura interna das relações pode não ser diretamente auditável por profissionais de saúde Kaur et al. (2021), Santos, Silva e Silva (2026). A vantagem interpretável das Redes Bayesianas também aparece em discussões recentes sobre geração sintética em saúde, especialmente quando há necessidade de preservar relações multivariadas e manter inspeção humana sobre a estrutura geradora Miletic e Sariyar (2026), Boni, Junior e Costa (2025).

2.4.3 Redes Bayesianas como Geradores Sintéticos

Além de apoiar inferência, Redes Bayesianas podem ser usadas para gerar dados sintéticos. Uma vez definida a estrutura e parametrizadas as distribuições, o modelo pode amostrar combinações de estados conforme as dependências probabilísticas especificadas. Assim, cada linha sintética representa uma combinação possível segundo o universo probabilístico definido pela rede Gelatti, Rodrigues e Carvalho (2021), Kaur et al. (2021), Goncalves et al. (2020).

No caso desta dissertação, a Rede Bayesiana não é aprendida a partir de dados reais. Sua topologia e suas CPTs são construídas a partir de conhecimento clínico, documentos normativos e decisões de modelagem. Essa escolha preserva a interpretabilidade e permite operar em cenário de *cold start*, mas também exige forte rastreabilidade das decisões adotadas Flores et al. (2023), Santos, Silva e Silva (2026), Silva et al. (2024a).

2.5 Human-in-the-Loop e Modelagem Knowledge-driven

A abordagem *Human-in-the-Loop* refere-se à participação humana em etapas críticas de construção, validação ou supervisão de sistemas computacionais. Em saúde, essa participação é especialmente importante porque decisões de modelagem podem envolver conhecimento tácito, julgamento clínico e interpretação de diretrizes Flores et al. (2023), Santos, Silva e Silva (2026).

2.5.1 Modelagem Orientada por Conhecimento

Em abordagens *data-driven*, a estrutura ou os parâmetros de um modelo são aprendidos diretamente a partir de dados observados. Em abordagens *knowledge-driven*, por outro lado, o conhecimento de domínio atua como fonte primária para definir variáveis, relações, probabilidades e regras de plausibilidade Kaur et al. (2021), Flores et al. (2023), Santos, Silva e Silva (2026).

Essa distinção é central para esta pesquisa. A proposta não busca descobrir automaticamente padrões em prontuários, mas representar formalmente um conjunto de hipóteses clínicas sobre a alta neonatal. A inteligência do modelo está na estrutura explícita do conhecimento, e não na memorização de uma base real, o que reduz a dependência de dados sensíveis e preserva a auditabilidade das premissas Goncalves et al. (2020), Murtaza et al. (2023), Santos, Silva e Silva (2026).

2.5.2 Papel dos Especialistas

Na construção de uma Rede Bayesiana *knowledge-driven*, especialistas podem contribuir em diferentes níveis. Primeiro, ajudam a selecionar variáveis relevantes para o domínio. Segundo, avaliam a direção e a plausibilidade das arestas no DAG. Terceiro, participam da elicitação ou revisão das probabilidades condicionais. Quarto, identificam combinações clinicamente implausíveis que devem ser auditadas ou restringidas Flores et al. (2023), Santos, Silva e Silva (2026), Kaur et al. (2021).

Essa participação não elimina incertezas, mas torna as premissas do modelo mais explícitas. Em vez de ocultar decisões em parâmetros aprendidos automaticamente, a modelagem orientada por conhecimento exige documentação, justificativa e possibilidade de revisão, elementos considerados centrais para auditabilidade em modelos clínicos interpretáveis Flores et al. (2023), Kaur et al. (2021), Santos, Silva e Silva (2026).

2.6 Seleção Incremental de Variáveis

A alta segura neonatal pode envolver um conjunto amplo de variáveis clínicas, familiares, preventivas e socioambientais. Entretanto, modelar simultaneamente todas essas variáveis pode tornar a Rede Bayesiana difícil de parametrizar, auditar e validar. Por isso, esta dissertação adota uma estratégia incremental de seleção de variáveis, compatível com a necessidade de reduzir

complexidade combinatória e preservar interpretabilidade clínica Silva et al. (2024a), Goncalves et al. (2020), Santos, Silva e Silva (2026).

2.6.1 Core11

O Core11 corresponde ao núcleo inicial da modelagem. Ele reúne 11 variáveis clínicas relacionadas à condição neonatal e à decisão de alta: Idade Gestacional (IG), Peso ao Nascer, Apgar no 5º minuto, Amamentação, Oxigenação, Respiração, Frequência Cardíaca, Temperatura, Icterícia, Triagens Neonatais e Vacina Santos, Silva e Silva (2026), Silva et al. (2024a), Almeida e Guinsburg (2026).

Esse conjunto foi utilizado como prova inicial da arquitetura. Seu papel é permitir o teste da estrutura básica da Rede Bayesiana, da geração sintética, do cálculo de escore e dos primeiros protocolos de validação. A inclusão da variável Vacina, embora não represente o maior peso biofisiológico direto, é relevante para testar dependências normativas e zeros estruturais associados ao peso ao nascer Sociedade Brasileira de Pediatria (2021), Santos, Silva e Silva (2026).

2.6.2 Core18

O Core18 representa a expansão principal avaliada nesta dissertação. Ele incorpora sete variáveis adicionais ao Core11: Eliminações, Exame Físico, Sinais de Alerta, Pressão Arterial, Coto Umbilical, Integridade da Pele e Sono Silva et al. (2024a), Santos, Silva e Silva (2026), Brasil. Ministério da Saúde (2014), Organização Pan-Americana da Saúde e Brasil. Ministério da Saúde (2014).

Essa expansão aumenta a cobertura biofisiológica do modelo e permite avaliar se a metodologia mantém coerência probabilística e topológica com maior complexidade. Ao mesmo tempo, a expansão evidencia a necessidade de auditoria clínica individual, pois novas variáveis aumentam o número de combinações possíveis e tornam mais visíveis limitações de plausibilidade linha a linha Goncalves et al. (2020), Araujo et al. (2023), Santos, Silva e Silva (2026).

2.6.3 Core25 como Horizonte Futuro

O Core25 é tratado nesta dissertação como horizonte futuro, e não como contribuição experimental validada. Ele representa uma possível continuidade da estratégia incremental, com inclusão de novas variáveis clínicas e preventivas previstas no horizonte normativo da alta segura neonatal Silva et al. (2024a), Santos, Silva e Silva (2026). Sua menção é útil para situar a progressão metodológica, mas os resultados e conclusões desta dissertação devem se restringir aos modelos Core11 e Core18.

Essa delimitação é importante para evitar extrapolações indevidas. A expansão para Core25 exigirá novas CPTs, novas arestas, novos protocolos de auditoria e validação clínica

adicional, em coerência com a lógica incremental adotada para controlar complexidade e preservar auditabilidade Goncalves et al. (2020), Santos, Silva e Silva (2026), Flores et al. (2023).

2.7 Tabelas de Probabilidade Condicional

As Tabelas de Probabilidade Condicional (CPTs) constituem a parte quantitativa de uma Rede Bayesiana. Elas definem a distribuição de probabilidade dos estados de uma variável em função dos estados de seus pais no DAG. Em variáveis sem pais, definem-se distribuições marginais; em variáveis condicionadas, definem-se probabilidades para cada combinação parental Kaur et al. (2021), Castro e Santos (2023).

2.7.1 Representação do Conhecimento

Em uma abordagem *knowledge-driven*, as CPTs traduzem conhecimento clínico em parâmetros probabilísticos. Essa tradução é uma etapa sensível, pois nem sempre a literatura oferece valores numéricos diretos para cada combinação de variáveis. Em muitos casos, há apenas direção de efeito, plausibilidade fisiológica ou consenso clínico Flores et al. (2023), Alur et al. (2023), Santos, Silva e Silva (2026).

Por isso, a construção de CPTs deve distinguir valores empiricamente ancorados, direções clinicamente justificadas e decisões de consenso. Essa distinção aumenta a honestidade metodológica e permite que versões futuras substituam probabilidades elicitadas por estimativas empíricas, caso bases reais se tornem disponíveis de forma ética e regulatória Flores et al. (2023), Alur et al. (2023).

2.7.2 Elicitação e Rastreabilidade

A elicitação de probabilidades é o processo pelo qual conhecimento especializado é transformado em distribuições numéricas. Esse processo deve ser documentado, revisável e coerente com a estrutura do DAG. Em modelos clínicos, a rastreabilidade é fundamental para que cada probabilidade possa ser associada a uma fonte normativa, referência bibliográfica, decisão de especialista ou premissa de modelagem Flores et al. (2023), Santos, Silva e Silva (2026).

No escopo desta dissertação, a rastreabilidade das CPTs sustenta a auditabilidade do modelo. Ela permite compreender por que uma variável foi incluída, por que determinada aresta foi estabelecida e como uma distribuição condicional foi parametrizada, reduzindo o risco de decisões arbitrárias em modelos orientados por conhecimento Flores et al. (2023), Santos, Silva e Silva (2026), Kaur et al. (2021).

2.8 Zeros Estruturais e Edit Checks Clínicos

Modelos probabilísticos podem gerar combinações raras, incoerentes ou clinicamente discutíveis quando dependências relevantes não são explicitamente representadas. Para lidar com esse problema, este trabalho distingue dois tipos de mecanismos: zeros estruturais e *edit checks* clínicos, ambos associados à necessidade de controlar plausibilidade em dados sintéticos de saúde Goncalves et al. (2020), Giuffrè e Shung (2023), Alaa et al. (2022), Hernandez et al. (2025).

2.8.1 Zeros Estruturais

Zeros estruturais são restrições incorporadas ao próprio processo de amostragem probabilística. Eles atribuem probabilidade nula a combinações consideradas impossíveis ou proibidas pela lógica normativa do modelo. Um exemplo é a regra que impede que recém-nascidos com muito baixo peso sejam classificados como vacinados quando essa condição é estruturalmente incompatível com a regra modelada Sociedade Brasileira de Pediatria (2021), Brasil. Ministério da Saúde (2014), Santos, Silva e Silva (2026).

Nesse caso, a restrição atua durante a geração dos dados. O registro não é gerado com aquela combinação porque a própria CPT define probabilidade zero para o estado proibido, seguindo a lógica de restrições determinísticas incorporadas ao modelo probabilístico Goncalves et al. (2020), Kaur et al. (2021).

2.8.2 Edit Checks Clínicos

Edit checks são regras de auditoria clínica aplicadas para identificar combinações potencialmente inconsistentes ou pouco plausíveis. Diferentemente dos zeros estruturais, no Core18 desta dissertação os *edit checks* são aplicados após a geração da base sintética. Eles não filtram automaticamente registros nem executam reamostragem condicionada Giuffrè e Shung (2023), Hernandez et al. (2025).

Essa distinção é metodologicamente importante. Ao manter os *edit checks* como auditoria pós-geração, torna-se possível observar o comportamento natural da Rede Bayesiana e quantificar os limites de plausibilidade clínica individual. Se essas regras fossem usadas diretamente como filtros, a base final poderia parecer mais plausível, mas seria necessário avaliar o impacto da filtragem sobre distribuições, dependências e fidelidade topológica Goncalves et al. (2020).

2.8.3 Plausibilidade Clínica Individual

A presença de *edit checks* reforça que coerência agregada não equivale a plausibilidade individual plena. Um gerador pode preservar distribuições marginais, inferências condicionais e estrutura topológica, mas ainda produzir algumas linhas sintéticas que merecem revisão clínica,

o que é coerente com a literatura que recomenda avaliar dados sintéticos por múltiplas dimensões de fidelidade, utilidade, privacidade e adequação ao uso Goncalves et al. (2020), Emam et al. (2022), Hernandez et al. (2025), Kaabachi et al. (2025).

Portanto, nesta dissertação, os *edit checks* não são apresentados como garantia absoluta de realismo biológico. Eles são tratados como uma camada de auditoria capaz de revelar fragilidades, orientar refinamentos e fundamentar trabalhos futuros, como filtragem clínica, reamostragem condicionada e calibração com especialistas.

2.9 Maldição da Dimensionalidade

A maldição da dimensionalidade descreve o aumento da complexidade de um problema à medida que cresce o número de variáveis consideradas. Em modelos tabulares e probabilísticos, esse crescimento pode produzir explosão combinatória, esparsidade e dificuldade de estimação ou elicitação de parâmetros Goncalves et al. (2020).

2.9.1 Complexidade em Redes Bayesianas

Em Redes Bayesianas, a complexidade está fortemente associada ao número de pais de cada nó e ao número de estados de cada variável. Uma CPT cresce de forma multiplicativa conforme aumentam as combinações parentais. Assim, adicionar variáveis sem controle pode tornar a parametrização extensa, difícil de auditar e suscetível a inconsistências Castro e Santos (2023), Goncalves et al. (2020).

Esse problema é especialmente relevante em modelos *Human-in-the-Loop*. Quanto maior o número de variáveis e dependências, maior a carga cognitiva para especialistas revisarem arestas, probabilidades e regras de plausibilidade. A expansão indiscriminada pode comprometer tanto a qualidade computacional quanto a qualidade clínica do modelo Flores et al. (2023), Santos, Silva e Silva (2026), Goncalves et al. (2020).

2.9.2 Expansão Incremental como Estratégia

A estratégia incremental adotada nesta dissertação busca mitigar esse problema. Ao iniciar pelo Core11 e avançar para o Core18, a pesquisa permite testar a arquitetura em etapas, comparar versões e identificar efeitos da expansão sobre os protocolos de validação Goncalves et al. (2020), Santos, Silva e Silva (2026).

Essa escolha preserva a interpretabilidade das variáveis e evita técnicas de redução dimensional que poderiam destruir significado clínico. Métodos como PCA podem ser úteis em outros contextos, mas não são adequados quando cada variável precisa manter interpretação clínica própria e relação explícita com regras normativas e *edit checks* Kaur et al. (2021).

Portanto, a expansão incremental não é apenas uma decisão operacional. Ela é uma estratégia metodológica para equilibrar abrangência clínica, viabilidade computacional, rastreabilidade e possibilidade de auditoria Kaur et al. (2021), Flores et al. (2023), Goncalves et al. (2020), Santos, Silva e Silva (2026).

2.10 Síntese do Capítulo

Este capítulo apresentou os fundamentos que sustentam a metodologia proposta. A alta segura neonatal foi caracterizada como um processo multidimensional de transição do cuidado, dependente de estabilidade clínica, prevenção, preparo familiar e seguimento Araujo et al. (2023), Queiroz et al. (2019), Sociedade Brasileira de Pediatria (2021), World Health Organization (2022), Silva et al. (2024a). Em seguida, discutiu-se o potencial da IA em saúde e os limites impostos por escassez de dados, privacidade e *cold start* Chen et al. (2021), Nisevic, Milojevic e Spajic (2025), Goncalves et al. (2020), Bernardino et al. (2024).

Os dados sintéticos foram apresentados como alternativa metodológica para pesquisa e desenvolvimento em saúde, desde que avaliados para além de métricas estatísticas simples Goncalves et al. (2020), Emam et al. (2022), Hernandez et al. (2025), Gonzales, Guruswamy e Smith (2023), Boni, Junior e Costa (2025), Kaabachi et al. (2025), Murtaza et al. (2023). As Redes Bayesianas foram discutidas como modelos probabilísticos interpretáveis, adequados à representação de conhecimento clínico e à geração de dados sintéticos em cenários sem bases reais Kaur et al. (2021), Flores et al. (2023), Miletic e Sariyar (2026), Santos, Silva e Silva (2026).

Também foram discutidos os papéis da abordagem *Human-in-the-Loop*, da seleção incremental de variáveis, das CPTs, dos zeros estruturais e dos *edit checks* Flores et al. (2023), Santos, Silva e Silva (2026). Por fim, discutiu-se a maldição da dimensionalidade como justificativa para a progressão Core11–Core18 e para o tratamento do Core25 como horizonte futuro Goncalves et al. (2020), Silva et al. (2024a).

Com essa fundamentação, o próximo capítulo pode posicionar a pesquisa em relação aos trabalhos relacionados, enquanto a metodologia detalha como esses conceitos foram operacionalizados no gerador sintético proposto, especialmente na articulação entre alta segura neonatal, dados sintéticos, Redes Bayesianas e curadoria clínica Silva et al. (2024a), Goncalves et al. (2020), Kaur et al. (2021), Santos, Silva e Silva (2026).

3
Metodologia

Este capítulo descreve a metodologia proposta para construção, expansão e validação de um modelo gerador de dados totalmente sintéticos para o contexto de alta segura neonatal. A abordagem adotada é *knowledge-driven*, isto é, orientada por conhecimento clínico normativo, literatura especializada e estruturação probabilística por Redes Bayesianas, em vez de aprendizado direto a partir de bases reais de pacientes.

O desenvolvimento metodológico foi conduzido de forma incremental, partindo de um modelo inicial com 11 variáveis clínicas, denominado Core11, e avançando para uma versão expandida com 18 variáveis clínicas, denominada Core18. Essa evolução permitiu avaliar não apenas a capacidade do modelo de gerar registros sintéticos coerentes, mas também a robustez da metodologia diante do aumento da complexidade topológica, do número de Tabelas de Probabilidade Condicional (CPTs) e das regras de validação.

O escopo desta pesquisa compreende exclusivamente a construção, execução e validação do modelo gerador em ambiente de simulação. Não está prevista no escopo deste trabalho a implementação do sistema em ambiente hospitalar real, tampouco sua utilização para diagnóstico ativo, prescrição, triagem operacional ou tomada de decisão clínica direta envolvendo pacientes. Assim, os resultados devem ser interpretados como contribuição metodológica para geração e avaliação de dados sintéticos neonatais, e não como validação assistencial de um sistema clínico em produção.

3.1 Visão Geral da Metodologia

A metodologia proposta busca responder à seguinte questão central: como traduzir conhecimento clínico normativo em um processo computacional replicável, capaz de gerar dados sintéticos neonatais sem depender da disponibilidade de registros reais de pacientes? Essa questão decorre de um cenário recorrente na saúde digital: a necessidade de desenvolver e testar modelos

computacionais em domínios sensíveis, nos quais bases reais podem ser escassas, restritas por privacidade ou indisponíveis na fase inicial de prova de conceito Chen et al. (2021), Goncalves et al. (2020), Jordon et al. (2022).

Ao contrário de abordagens gerativas estritamente orientadas a dados, como modelos que inferem distribuições a partir de grandes volumes de prontuários reais, a estratégia adotada nesta dissertação não parte de uma base institucional de pacientes. Em cenários data-driven, além da necessidade de grande volume de registros, há riscos metodológicos associados à privacidade, à memorização de padrões individuais e à geração de combinações clinicamente incoerentes quando o algoritmo aprende correlações sem restrições explícitas de domínio Tucker et al. (2020), Yale et al. (2020), Giuffrè e Shung (2023), Kaabachi et al. (2025). A opção knowledge-driven busca contornar esse problema ao posicionar o conhecimento clínico, a rastreabilidade normativa e a curadoria humana como fontes primárias de estruturação do gerador.

Para enfrentar esse problema, a pesquisa estruturou um pipeline metodológico composto por oito etapas, organizadas em três fases: fundamentação e modelagem, implementação e geração, e validação multidimensional. A Figura 1 sintetiza esse fluxo, articulando desde a priorização das variáveis clínicas e a rastreabilidade bibliográfica até a geração sintética, a classificação da decisão de alta e a validação por protocolos estatísticos, topológicos, explicativos e de plausibilidade clínica.

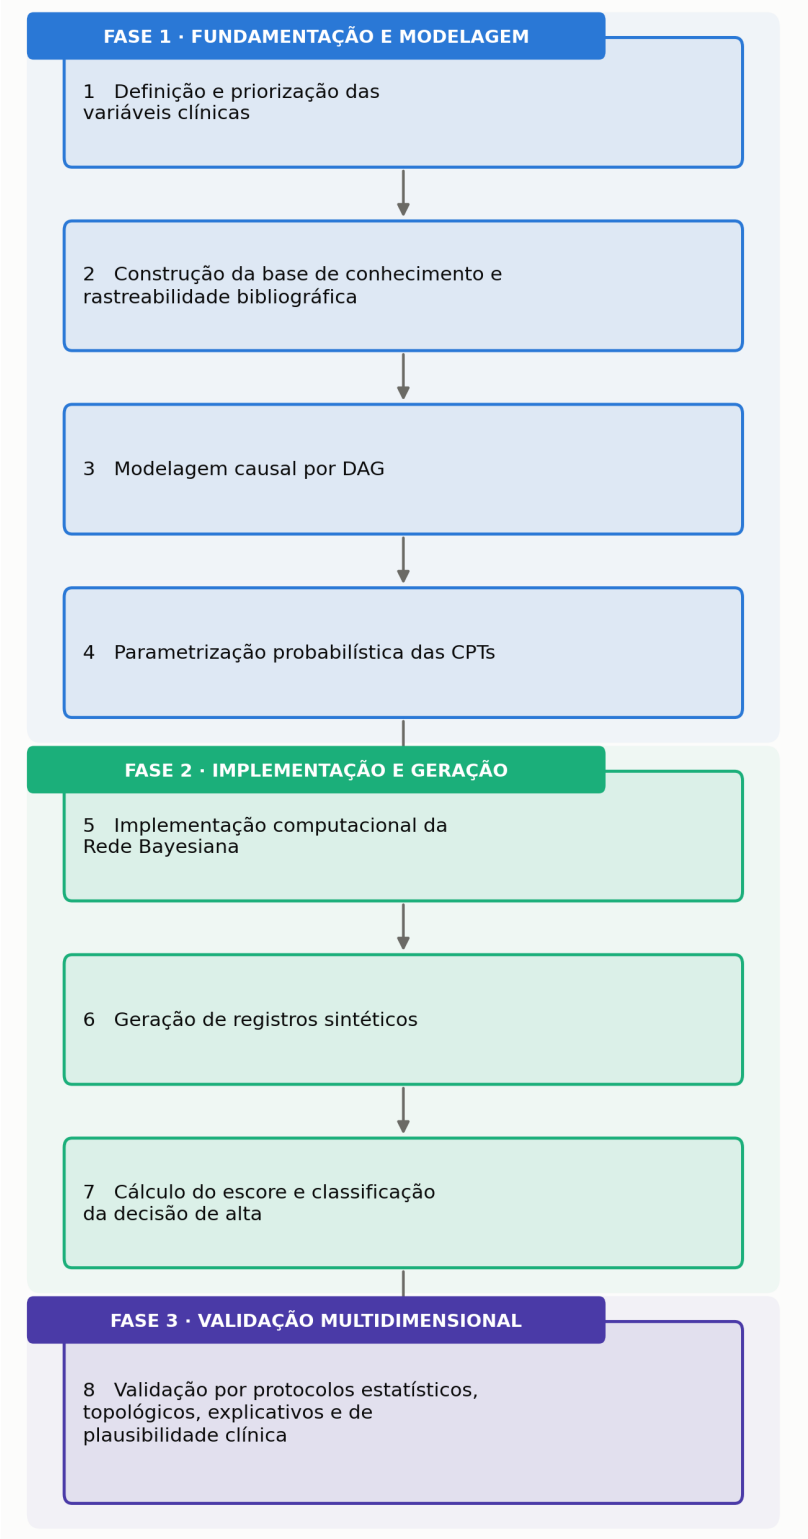


Figura 1 – Pipeline metodológico de geração, classificação e validação dos dados sintéticos neonatais.

Fonte: Produção dos autores, 2026

O caráter incremental da metodologia é central para o desenho da pesquisa. Em vez de modelar simultaneamente todo o conjunto normativo de variáveis neonatais, optou-se por construir versões progressivas do modelo, permitindo testar a estabilidade da arquitetura e a capacidade de expansão do gerador. O Core11 foi utilizado como prova inicial da arquitetura; o Core18, por sua vez, foi adotado como versão final desta dissertação, por representar uma expansão clinicamente mais abrangente e computacionalmente validada em ambiente de simulação.

3.2 Desenho da Pesquisa

Esta pesquisa caracteriza-se como um estudo metodológico-computacional, de natureza construtiva e aplicada. Seu objetivo não é observar uma coorte real de recém-nascidos, nem comparar diretamente decisões clínicas reais com decisões algorítmicas, mas sim construir e avaliar uma metodologia de geração sintética baseada em conhecimento de domínio.

O desenho adotado aproxima-se de uma lógica de desenvolvimento de artefato computacional: define-se um problema de domínio, constrói-se uma representação formal desse domínio, implementa-se um gerador probabilístico e avalia-se o comportamento do artefato por meio de métricas internas e protocolos de consistência. Essa escolha é coerente com a ausência de uma base real inicial e com a proposta de dados totalmente sintéticos, isto é, registros gerados artificialmente sem cópia ou transformação direta de prontuários individuais Goncalves et al. (2020), Rajotte et al. (2022), Tucker et al. (2020).

Este estudo está inserido no âmbito do projeto de pesquisa guarda-chuva intitulado "Desenvolvimento e Validação de Aplicativo para Alta Segura do Recém-Nascido para Equipe de Saúde", que reúne uma equipe multidisciplinar de pesquisadores composta por docentes, profissionais de saúde, doutores, mestrandos e doutorandos, atuando de forma articulada na mesma linha de investigação. O referido projeto encontra-se devidamente registrado junto à Universidade Federal da Bahia (UFBA) e conta com a aprovação do Comitê de Ética em Pesquisa da Escola de Enfermagem da UFBA (CEP/UFBA) sob o parecer nº 8.484.157 (CAAE: 64756722.6.0000.5531), o que assegura o respaldo ético, o vínculo institucional e a integração desta dissertação a um esforço coletivo e continuado voltado à segurança do processo de alta neonatal Universidade Federal da Bahia. Escola de Enfermagem. Comitê de Ética em Pesquisa (2026).

Por utilizar uma abordagem puramente baseada em conhecimento (knowledge-driven) e orientada pela privacidade desde a concepção (privacy-by-design), a modelagem e a síntese dos dados nesta dissertação prescindiram do acesso ou manipulação direta de prontuários reais de pacientes, em estrita observância às diretrizes das Resoluções nº 466/2012 e nº 510/2016 do Conselho Nacional de Saúde (CNS) e à Lei Geral de Proteção de Dados Pessoais (LGPD).

A validação realizada nesta etapa segue o regime *Train on Synthetic, Test on Synthetic* (TSTS). Nesse regime, os dados sintéticos são avaliados por sua coerência interna, por sua

preservação das distribuições e das dependências impostas pela rede e por sua utilidade preditiva dentro do próprio universo simulado. O regime *Train on Synthetic, Test on Real* (TSTR), frequentemente usado quando há uma base real disponível para comparação, permanece fora do escopo desta dissertação. Assim, a utilidade preditiva reportada neste trabalho deve ser interpretada como evidência de estrutura analítica interna ao universo sintético, e não como validade preditiva clínica externa Rankin et al. (2020), Hernandez et al. (2025).

3.3 Construção da Base de Conhecimento

A base de conhecimento constitui o alicerce da metodologia. Como o modelo não aprende suas probabilidades a partir de uma base histórica de pacientes, as variáveis, dependências, probabilidades condicionais e regras de plausibilidade precisam ser justificadas por fontes clínicas, normativas e por critérios de engenharia do conhecimento.

Foram utilizados documentos técnicos produzidos ao longo da pesquisa para registrar as decisões metodológicas, a construção das CPTs, a justificativa das arestas e os edit checks clínicos. Esses documentos funcionam como artefatos de rastreabilidade, permitindo reconstruir por que uma variável foi incluída, por que uma aresta foi definida e como determinada probabilidade foi parametrizada.

Tabela 1 – Artefatos documentais utilizados na metodologia

Documento	**Função metodológica**
CPTs do Core18	Registro das CPTs utilizadas na expansão para o Core18.
Construção das CPTs	Descrição dos critérios de construção e parametrização das CPTs.
Embasamento normativo	Fundamentação normativa das variáveis clínicas consideradas para expansão.
Justificativa das arestas	Justificativa clínica e estrutural das dependências do DAG.
Rastreabilidade bibliográfica	Registro de rastreabilidade bibliográfica e normativa.
Validação clínica dos edit checks	Base conceitual para validação clínica por edit checks.
Tabela operacional dos edit checks	Tabela operacional das regras de consistência clínica aplicadas ao Core18.

Fonte: Produção dos autores, 2026

As versões sintetizadas dos artefatos metodológicos da Tabela 1 encontram-se nos Apêndices A, B, C e D.

3.3.1 Levantamento Bibliográfico e Rastreabilidade

O levantamento bibliográfico teve como finalidade sustentar a escolha de variáveis, a direção das relações causais e as regras de plausibilidade clínica. A literatura sobre alta segura neonatal e transição de cuidados Araujo et al. (2023), Queiroz et al. (2019), Silva et al. (2024a) fundamentou o escopo clínico. Simultaneamente, as estratégias de validação e a modelagem probabilística por redes bayesianas foram ancoradas em referências técnicas consolidadas na avaliação de dados sintéticos em saúde Goncalves et al. (2020), Emam et al. (2022), Kaur et al. (2021).

A rastreabilidade foi tratada como requisito metodológico. Cada decisão relevante do modelo deveria poder ser vinculada a pelo menos uma das seguintes camadas: fonte normativa, literatura científica, documento técnico da pesquisa ou decisão de modelagem explicitamente registrada. Essa estratégia reduz o risco de parametrizações arbitrárias e permite que futuras revisões do modelo possam identificar exatamente quais partes da estrutura dependem de determinada premissa.

3.3.2 Participação Humana e Curadoria Clínica

A abordagem *Human-in-the-Loop* foi empregada como princípio de curadoria do conhecimento. Nesse contexto, o papel humano não se restringe à rotulagem de dados, mas envolve a validação conceitual da estrutura do modelo: seleção de variáveis, definição de dependências, avaliação de plausibilidade das relações e interpretação dos resultados.

Em modelos clínicos baseados em conhecimento, a participação humana é particularmente relevante porque nem toda decisão pode ser reduzida a um critério estatístico. Em alguns casos, a literatura sustenta a direção de uma relação, mas não fornece uma probabilidade exata; em outros, a coerência fisiológica exige restrições que uma Rede Bayesiana puramente probabilística não imporia sozinha. A curadoria clínica, portanto, atua como mecanismo de controle epistêmico e de adequação do modelo ao domínio neonatal.

3.4 Seleção Incremental das Variáveis

A seleção das variáveis foi realizada de forma incremental, considerando a relevância normativa e a necessidade de preservar interpretabilidade. Em vez de empregar métodos de redução dimensional puramente estatísticos, como extração automática de componentes, a pesquisa priorizou variáveis clinicamente interpretáveis e justificáveis no domínio de alta segura neonatal.

O instrumento normativo utilizado como referência organiza a alta segura neonatal como um fenômeno multidimensional, composto por variáveis clínicas e contextuais distribuídas em seis eixos: condições de parto e nascimento, prontidão biofisiológica, testagens neonatais,

prontidão e comunicação com os pais, seguimento de rede de atenção e condições socioambientais da família Silva et al. (2024a). Essa estrutura é compatível com recomendações nacionais e internacionais que tratam a alta neonatal e o cuidado pós-natal como processos integrados, dependentes de estabilidade clínica, orientação familiar, identificação de sinais de perigo e continuidade assistencial Sociedade Brasileira de Pediatria (2021), Brasil. Ministério da Saúde (2016), Brasil. Ministério da Saúde (2015), World Health Organization (2022), Organização Pan-Americana da Saúde e Brasil. Ministério da Saúde (2014). Essa estrutura reforça que a alta neonatal não é determinada por um único marcador, mas por um conjunto articulado de condições fisiológicas, preventivas, familiares e assistenciais.

Apesar dessa abrangência, a modelagem simultânea de todas as variáveis impõe desafios matemáticos e computacionais. Em redes bayesianas, o tamanho de uma CPT cresce em função do número de pais de cada nó e da quantidade de estados possíveis desses pais. Assim, quanto maior o número de variáveis e dependências, maior o esforço de parametrização, maior o risco de esparsidade e maior a dificuldade de auditoria manual. A estratégia incremental adotada nesta dissertação foi, portanto, uma decisão metodológica para controlar a complexidade, preservar rastreabilidade e permitir validação progressiva.

Essa decisão é relevante porque o objetivo do trabalho não é apenas gerar dados com boa aparência estatística, mas construir um modelo capaz de explicar suas variáveis, suas dependências e suas regras de geração. A preservação semântica dos nós é fundamental para que profissionais e pesquisadores possam auditar o modelo.

3.4.1 Core11

O Core11 corresponde ao modelo inicial da pesquisa, composto por 11 variáveis clínicas. Essa versão atuou como prova de conceito da arquitetura knowledge-driven, permitindo testar a construção da Rede Bayesiana, a parametrização das CPTs, a geração sintética, o cálculo do escore e os primeiros protocolos de validação.

As variáveis do Core11 foram: Idade Gestacional (IG), Peso, Apgar, Amamentação, Oxigenação, Respiração, Frequência Cardíaca (FC), Temperatura, Icterícia, Triagens e Vacina. A partir dessas variáveis, foram geradas amostras sintéticas e classificações de decisão de alta. O uso de Apgar e parâmetros cardiorrespiratórios como marcadores de gravidade e adaptação neonatal é coerente com diretrizes de reanimação e cuidado neonatal, embora a diretriz mais recente da SBP seja utilizada nesta dissertação como reforço de plausibilidade clínica, e não como fonte histórica única da modelagem original Almeida e Guinsburg (2026), Brasil. Ministério da Saúde (2014).

Na execução analisada nesta dissertação, o Core11 foi avaliado com $n = 10000$ registros sintéticos, armazenados no experimento `01_Core11_Baseline`. Essa execução será retomada no capítulo de resultados para comparação com o Core18.

3.4.2 Core18

O Core18 representa a expansão do Core11 pela incorporação de sete novas variáveis clínicas: Eliminações, Exame Físico, Sinais de Alerta, Pressão Arterial (PA), Coto Umbilical, Pele e Sono. A inclusão dessas variáveis teve como objetivo ampliar a cobertura biofisiológica do modelo e testar a capacidade da metodologia de crescer sem perder coerência probabilística, topológica e interpretativa. Sinais de alerta, exame físico, eliminação, integridade da pele, coto umbilical e estabilidade térmica são dimensões compatíveis com recomendações de atenção neonatal e identificação de risco no período pós-natal Brasil. Ministério da Saúde (2014), Organização Pan-Americana da Saúde e Brasil. Ministério da Saúde (2014), Sociedade Brasileira de Pediatria (2021), World Health Organization (2022).

A expansão exigiu mudanças em múltiplas camadas do pipeline: inclusão dos novos nós, definição dos estados possíveis, atualização de pesos e pontuações, construção de novas CPTs, atualização do cálculo do escore, ampliação dos protocolos de validação, geração de gráficos compatíveis com 18 variáveis e criação do Protocolo EC como camada de auditoria de plausibilidade clínica interna.

O Core18 foi adotado como versão final desta dissertação por representar uma expansão metodológica suficiente para demonstrar escalabilidade em relação ao Core11, sem abrir uma nova frente experimental ainda não estabilizada. A versão Core25 é tratada nesta pesquisa como perspectiva futura.

3.4.3 Core25 como Perspectiva Futura

Embora documentos de planejamento contemplem a possibilidade de expansão para um modelo Core25, esta dissertação encerra sua contribuição experimental no Core18. A decisão metodológica busca preservar a robustez do trabalho entregue: o Core11 estabelece a prova inicial da arquitetura, e o Core18 demonstra expansão validada em ambiente de simulação.

O Core25 permanece como continuidade natural da pesquisa, podendo incorporar novas variáveis, novas CPTs, novas arestas e novos edit checks. A experiência obtida com o Core18 indica que uma expansão futura deve considerar não apenas a inclusão de variáveis, mas também mecanismos mais ativos de controle de plausibilidade clínica.

3.5 Modelagem Causal da Rede Bayesiana

A Rede Bayesiana foi utilizada como estrutura formal para representar dependências condicionais entre variáveis neonatais. Cada nó do DAG representa uma variável clínica discreta, enquanto cada aresta representa uma relação de dependência probabilística orientada. A escolha desse formalismo se justifica pela interpretabilidade, pela capacidade de incorporar conhecimento de domínio e pela adequação a cenários de incerteza Kaur et al. (2021), Flores et al. (2023).

3.5.1 Definição da DAG

A definição da DAG partiu da identificação dos nós raiz e dos nós condicionados. Variáveis como IG atuam como determinantes estruturais importantes, influenciando outras variáveis biofisiológicas. Outras variáveis, por sua vez, dependem de combinações de estados clínicos, como sinais vitais, peso, oxigenação ou condições observáveis no exame físico.

O DAG não foi construído por descoberta estatística automática, pois não havia uma base real de treinamento. Em abordagens data-driven, a estrutura de uma rede pode ser inferida por algoritmos de aprendizado estrutural, como PC ou K2, ou por testes de independência condicional aplicados a registros observados Castro e Santos (2023). Nesta pesquisa, essa etapa foi substituída por modelagem manual orientada por conhecimento: a topologia foi definida a partir de raciocínio fisiopatológico, documentação normativa e coerência com as CPTs. Essa abordagem é coerente com o objetivo da pesquisa: gerar dados totalmente sintéticos a partir de conhecimento estruturado, e não reproduzir padrões aprendidos de uma coorte real.

A Figura 2 apresenta a topologia da Rede Bayesiana na versão Core18, evidenciando as dependências condicionais modeladas entre as variáveis clínicas utilizadas na geração sintética.

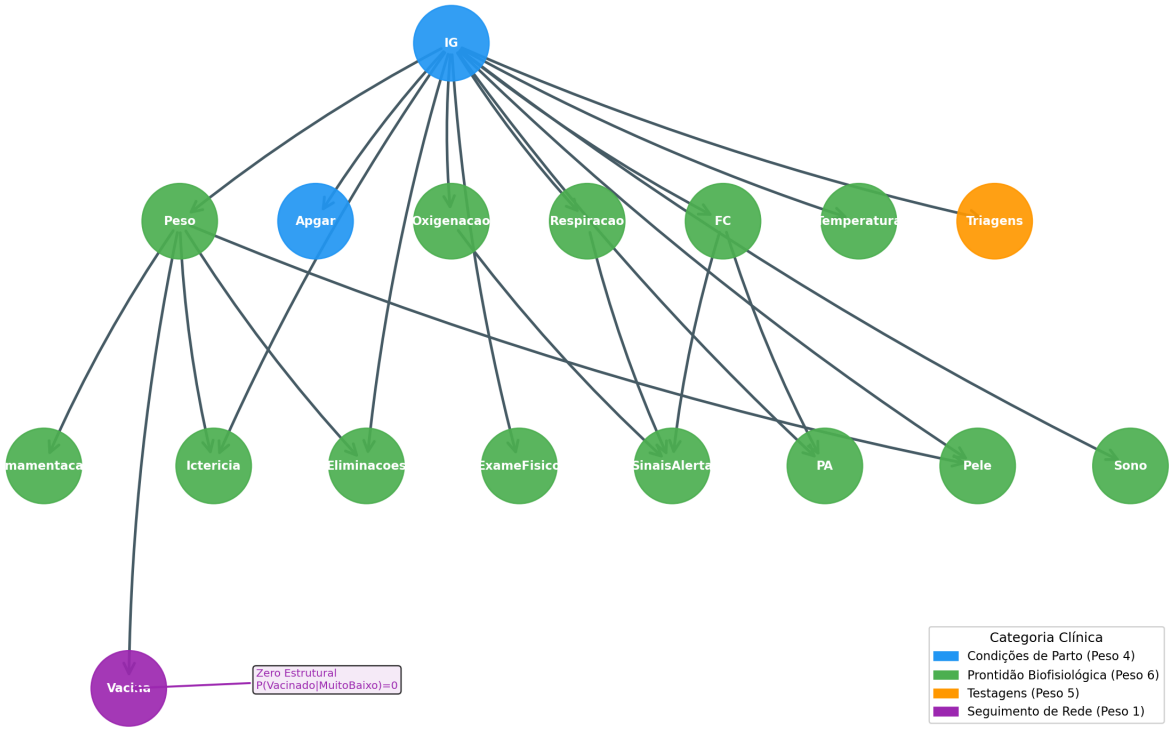


Figura 2 – Topologia da Rede Bayesiana na versão Core18.

Fonte: Produção dos autores, 2026

Como exemplo da lógica causal adotada, a Idade Gestacional (IG) atua como variável estrutural de grande influência no domínio biofisiológico. Ela condiciona a distribuição de variáveis como Peso, Apgar e parâmetros cardiorrespiratórios, refletindo a relação esperada entre

prematuridade, adaptação fisiológica e risco neonatal. Essa amarração evita que a rede produza registros como combinações independentes de atributos, preservando um encadeamento clínico plausível entre características do recém-nascido.

3.5.2 Justificativas Clínicas das Arestas

Cada aresta da rede deve possuir justificativa metodológica. A presença de uma dependência não indica apenas associação estatística, mas uma hipótese de influência ou condicionamento clínico relevante para a geração sintética. A matriz de justificativa das arestas foi utilizada para registrar essas relações e reduzir divergências entre documentação, CPTs e implementação.

Na expansão para o Core18, essa etapa tornou-se especialmente importante, pois a inclusão de novos nós aumenta o risco de inconsistências estruturais. Por exemplo, uma variável pode aparecer documentada como dependente de determinado pai, mas ser implementada no código com outro conjunto de pais. A auditoria das arestas busca evitar esse tipo de desalinhamento.

3.5.3 Auditoria de Consistência Estrutural

A consistência estrutural foi tratada como requisito de qualidade do modelo. O objetivo da auditoria estrutural é verificar se há correspondência entre três camadas: a documentação da topologia, as CPTs efetivamente definidas e a implementação computacional no código.

Nesta dissertação, essa auditoria é entendida como uma prática metodológica necessária para modelos knowledge-driven. Como as relações não são aprendidas automaticamente a partir de dados reais, qualquer divergência entre documentação e implementação compromete a rastreabilidade da rede. Assim, a consistência estrutural não é apenas uma questão de organização do código, mas parte da validade interna do modelo.

3.5.4 Validação Clínica da Topologia

A validação clínica da topologia causal deve ser distinguida da validação estatística do gerador. A validação estatística avalia se o modelo executado respeita as probabilidades e dependências implementadas; a validação clínica avalia se essas dependências são aceitáveis no domínio neonatal.

No escopo desta dissertação, a topologia foi construída a partir de documentos normativos, literatura e curadoria de conhecimento. Entretanto, a validação formal em ambiente assistencial, com homologação prospectiva por equipe clínica e uso operacional, não faz parte do escopo. Essa delimitação deve ser explicitada para evitar a interpretação de que o modelo foi certificado para uso clínico direto.

3.6 Construção das Tabelas de Probabilidade Condicional

As CPTs são o componente quantitativo da Rede Bayesiana. Enquanto o DAG define quais variáveis se relacionam, as CPTs definem como os estados de uma variável se distribuem em função dos estados de seus pais. Em um modelo knowledge-driven, a construção dessas tabelas é uma das etapas mais sensíveis, pois transforma conhecimento clínico qualitativo em parâmetros probabilísticos.

3.6.1 Processo de Elicitação

O processo de elicitação seguiu uma hierarquia de preferência: quando havia valor diretamente documentado, esse valor era priorizado; quando havia apenas indicação de direção ou intensidade relativa, a probabilidade era construída de modo coerente com essa direção; quando a evidência era insuficiente para valor numérico exato, a parametrização era tratada como decisão de modelagem rastreável.

Na prática, a elicitação combinou quatro camadas: literatura científica e documentos normativos, documentos técnicos produzidos durante a pesquisa, coerência fisiopatológica do domínio neonatal e revisão humana das escolhas estruturais. Essa combinação permitiu converter conhecimento qualitativo em distribuições condicionais explícitas, sem apresentar as CPTs como estimativas epidemiológicas derivadas de coorte real. As probabilidades devem ser entendidas, portanto, como parâmetros de um gerador sintético knowledge-driven, passíveis de refinamento futuro por calibração empírica.

Essa distinção é importante para honestidade epistêmica. Nem toda probabilidade em uma CPT possui o mesmo grau de ancoragem empírica. Ao registrar essa diferença, a metodologia permite que revisões futuras substituam valores elicitados por valores empiricamente estimados, caso bases reais venham a se tornar disponíveis.

3.6.2 Parametrização

A parametrização consistiu em preencher as distribuições condicionais de cada variável de modo que a soma das probabilidades de seus estados fosse igual a 1 para cada combinação de pais. No caso de variáveis sem pais, foram definidas distribuições marginais. No caso de variáveis condicionadas, foram especificadas distribuições para cada combinação dos estados parentais.

No Core18, a parametrização foi ampliada para acomodar novas variáveis e novas dependências. Essa expansão aumentou o número de cenários condicionais e, consequentemente, a necessidade de testes de regressão e validação automatizada. Por isso, os protocolos S1, S2 e S7 foram adaptados para avaliar a coerência das novas distribuições.

Do ponto de vista computacional, a implementação foi realizada em Python com apoio da biblioteca `pomegranate` em sua API legada 0.14.x, utilizada para representar e amostrar

a Rede Bayesiana. A definição manual das distribuições nessa biblioteca preserva a lógica knowledge-driven do modelo: a inteligência do gerador não deriva da memorização de uma base hospitalar específica, mas da estrutura causal e probabilística explicitamente definida no código.

3.6.3 Validação das CPTs

A validação das CPTs foi realizada por inspeção estrutural e por testes computacionais. O protocolo S1 avaliou marginais e dependências fundamentais, enquanto o protocolo S2 testou inferências condicionais e zeros estruturais especificados. No Core18, o S2 foi expandido de 7 para 14 casos de validação, incorporando regras relacionadas às novas variáveis.

Essa validação é necessária porque uma CPT pode estar sintaticamente correta, mas produzir comportamento probabilístico inadequado. A geração amostral permite observar se as frequências empíricas do dataset sintético são compatíveis com as probabilidades teóricas impostas pelo modelo.

3.6.4 Zeros Estruturais

Zeros estruturais são restrições que atribuem probabilidade nula a combinações consideradas impossíveis ou metodologicamente proibidas. Eles são relevantes porque impedem que o processo de amostragem gere determinados cruzamentos, mesmo que outras variáveis do modelo pudessem tornar esses cruzamentos estatisticamente prováveis.

Um exemplo usado na validação é a regra $P(\text{Vacinado} \mid \text{Peso} = \text{MuitoBaixo}) = 0$. Essa regra impede que recém-nascidos com peso muito baixo sejam classificados como vacinados em uma situação na qual esse estado foi definido como estruturalmente incompatível no modelo. A presença de zeros estruturais reforça que a metodologia não é apenas probabilística, mas também incorpora restrições normativas explícitas.

3.7 Construção dos Edit Checks

Os edit checks são regras de auditoria clínica utilizadas para identificar combinações internamente pouco plausíveis no dataset sintético. Diferentemente dos zeros estruturais implementados diretamente nas CPTs, os edit checks do Core18 foram aplicados como auditoria pós-geração, permitindo quantificar violações sem impedir a geração ou o salvamento da linha.

3.7.1 Definição

No contexto desta pesquisa, um edit check é uma regra lógica que cruza estados de duas ou mais variáveis para identificar inconsistências clínicas potenciais. Exemplos incluem combinações como Apgar deprimido com sono adequado, hipoxemia com respiração normal, temperatura alterada com sinais de alerta ausentes ou hipotensão associada a decisão de alta.

Essas regras não devem ser interpretadas como diagnóstico clínico, mas como mecanismos internos de controle de qualidade do dataset sintético. Sua função é indicar ao pesquisador quais tipos de combinações merecem cautela interpretativa ou refinamento futuro.

3.7.2 Validação Clínica e Papel Metodológico

O Protocolo EC foi introduzido no Core18 como camada complementar aos protocolos S1–S7. Enquanto S1, S2 e S7 avaliam propriedades probabilísticas e topológicas, o EC avalia a plausibilidade clínica linha a linha. Essa diferença é fundamental: uma base sintética pode ser adequada no agregado e ainda conter registros individuais clinicamente estranhos.

Na versão final analisada nesta dissertação, o conjunto de edit checks do Core18 foi composto por 14 regras. A regra EC-01 audita a combinação entre Apgar deprimido e sono adequado, interpretada como pouco plausível porque depressão neonatal importante é incompatível com um padrão fisiológico de sono adequado em um recém-nascido clinicamente estável. No estado agregado do modelo, essa regra foi operacionalizada como `Apgar = Deprimido` e `Sono = Adequado`. Seu papel é sinalizar inconsistência para auditoria metodológica; ela não altera CPTs, escore, decisão de alta ou processo de amostragem.

Nesta dissertação, o EC é tratado como auditoria de plausibilidade interna, não como certificação clínica para uso assistencial. O resultado do EC permite caracterizar os limites do gerador e orientar trabalhos futuros, especialmente no que diz respeito à possível adoção de filtros, rejeição de amostras ou reamostragem condicionada por regras críticas.

3.7.3 Integração com a Rede Bayesiana

Na versão Core18, os edit checks foram integrados como etapa posterior à geração do dataset. Portanto, a Rede Bayesiana gera os registros conforme suas distribuições e dependências, e o Protocolo EC audita as linhas resultantes. Essa escolha preserva a capacidade de observar o comportamento natural do gerador, mas também revela onde a rede, isoladamente, não impõe todas as restrições clínicas desejáveis.

Optou-se deliberadamente por empregar o Protocolo EC como camada de auditoria pós-geração, e não como mecanismo automático de rejeição ou reamostragem. Essa decisão metodológica preserva a observação do comportamento natural do gerador probabilístico, permitindo mensurar em que medida a Rede Bayesiana, isoladamente, produz combinações clinicamente plausíveis ou inconsistentes. Caso os edit checks fossem usados para descartar automaticamente registros, o dataset final poderia apresentar maior plausibilidade aparente, mas seria necessário avaliar adicionalmente o impacto da filtragem sobre as distribuições marginais, as dependências condicionais e a fidelidade topológica do modelo. Assim, nesta dissertação, o EC é tratado como instrumento de auditoria e caracterização dos limites do gerador, enquanto seu uso como mecanismo ativo de rejeição ou reamostragem é reservado como trabalho futuro.

Essa separação entre geração e auditoria foi metodologicamente útil para a dissertação, pois demonstrou que coerência probabilística global não garante plausibilidade clínica individual em todas as linhas. A constatação é uma contribuição relevante para o uso crítico de dados sintéticos em saúde.

3.8 Implementação Computacional

A implementação computacional foi realizada no arquivo `modelo_bn_dissertacao.py`. Esse arquivo concentra a definição das variáveis, estados, CPTs, pesos, cálculo do escore, decisão de alta, geração dos dados sintéticos, produção de gráficos, exportação dos datasets e execução dos protocolos de validação. A implementação utiliza Python e a biblioteca `pomegranate` para operacionalizar a Rede Bayesiana, além de bibliotecas auxiliares para manipulação tabular, análise estatística, aprendizado de máquina e geração de visualizações.

3.8.1 Arquitetura do Código

A arquitetura do código foi organizada em blocos funcionais. O primeiro bloco define constantes, variáveis e mapas de pontuação. O segundo constrói a estrutura da Rede Bayesiana e suas CPTs. O terceiro realiza a amostragem e monta o dataset. O quarto calcula o escore e deriva a decisão de alta. O quinto executa validações, gera métricas e salva artefatos experimentais.

Essa organização permite que a mesma base de código suporte diferentes versões do modelo, desde que as variáveis, pesos, CPTs e protocolos sejam atualizados de forma coerente. A passagem do Core11 para o Core18 exigiu alterações em todas essas camadas, o que reforça a importância dos testes de regressão.

3.8.2 Algoritmo de Geração

O processo de geração pode ser resumido pelo Algoritmo 1. O objetivo do algoritmo é produzir registros sintéticos independentes, cada um composto por estados clínicos amostrados conforme a estrutura probabilística da rede.

Fonte: Produção dos autores, 2026

3.8.3 Processo de Geração e Saída

Cada execução gera um dataset tabular com as variáveis clínicas, o `ScoreTotal` e a variável `DecisaoAlta`. No Core11, o dataset analisado possui 13 colunas; no Core18, possui 20 colunas, refletindo a inclusão de sete novas variáveis clínicas.

Data: Número de amostras n, versão do modelo, CPTs, pesos e diretório de experimento
Result: Dataset sintético, métricas de validação e artefatos experimentais
Inicializar variáveis, estados, pesos e limiares
Construir a Rede Bayesiana e associar as CPTs
for $i \leftarrow 1$ **to** n **do**
    Amostrar os estados clínicos do registro i conforme a rede
    Calcular o *ScoreTotal* do registro
    Aplicar regras de decisão para classificar a alta
    Armazenar o registro sintético
end
Exportar dataset sintético
Executar protocolos S1–S7
if *modelo* = *Core18* **then**
    Executar Protocolo EC
end
Salvar métricas, gráficos, relatório e metadados de execução

Algorithm 1: Pipeline de geração e validação dos dados sintéticos

Além dos datasets, a execução gera métricas em formato `JSON` e `CSV`, gráficos, relatório de ata e arquivos de ambiente. Esses artefatos permitem auditar a execução e comparar resultados entre versões do modelo.

3.9 Sistema de Escore e Classificação da Decisão de Alta

Após a geração dos estados clínicos, cada registro recebe uma pontuação total. O escore representa uma síntese normativa das condições observadas no registro sintético. Estados considerados mais favoráveis recebem maior pontuação, enquanto estados de maior risco recebem menor pontuação.

Diferentemente das variáveis clínicas, que são amostradas probabilisticamente pela Rede Bayesiana, a variável `DecisaoAlta` é derivada de forma determinística. Isso significa que o rótulo final não é sorteado: ele resulta da aplicação do sistema de escore e dos limiares normativos sobre o perfil sintético gerado. Essa separação é metodologicamente importante, pois mantém o quadro clínico como produto probabilístico da rede e a decisão de alta como consequência normativa das condições simuladas.

Tabela 2 – Parâmetros de escore nas versões Core11 e Core18

Modelo	Variáveis clínicas	Score máximo	Limiar normativo
Core11	11	168	112
Core18	18	294	196

Fonte: Produção dos autores, 2026

A decisão de alta é derivada do escore e dos limiares normativos definidos para cada

versão do modelo. As classes consideradas são: Alta Segura, Alta com Recomendação e Alta Contraindicada. A inclusão de novas variáveis no Core18 tornou a classificação mais conservadora para Alta Segura, pois aumentou o número de dimensões clínicas que precisam estar em condição favorável para que uma linha sintética seja classificada como segura.

Essas classes devem ser interpretadas como categorias normativas simuladas. A classe Alta Segura representa o cenário em que o registro sintético atinge as condições exigidas pelo instrumento para liberação sem recomendações adicionais relevantes. A classe Alta com Recomendação representa situações intermediárias, nas quais o perfil sintético exige observações, encaminhamentos ou atenção a riscos residuais. A classe Alta Contraindicada representa perfis nos quais o conjunto de condições geradas indica risco incompatível com a liberação no modelo normativo. Em nenhum caso essas categorias correspondem a recomendação assistencial real para pacientes.

3.10 Estratégia de Validação

A validação foi estruturada como um conjunto de protocolos complementares. Essa decisão decorre da natureza multidimensional do problema: não basta verificar se o dataset possui distribuições marginais adequadas; também é necessário avaliar inferências condicionais, topologia, utilidade preditiva, sensibilidade de limiares, casos paradoxais e plausibilidade clínica.

A estratégia de validação foi organizada em protocolos complementares, voltados a avaliar dimensões distintas do gerador sintético e do instrumento normativo de decisão. A Figura 3 sintetiza essa organização, distinguindo os protocolos voltados à validação do gerador, os protocolos voltados à validação do instrumento normativo e o Protocolo EC, aplicado como camada complementar de auditoria clínica interna no Core18.

Os protocolos foram definidos para produzir tanto confirmações quanto achados críticos. Portanto, reprovações, divergências ou instabilidades em protocolos como S3SHAP, S4, S5 e EC não devem ser interpretadas como falhas a serem ocultadas, mas como evidências metodológicas sobre os limites do gerador e do instrumento normativo no ambiente sintético.

Para fins de organização metodológica, os protocolos podem ser agrupados em dois blocos. O primeiro avalia o gerador propriamente dito, considerando fidelidade estatística, inferência condicional, utilidade preditiva interna e fidelidade topológica multivariada. Esse bloco é composto pelos protocolos S1, S2, S3 e S7. O segundo avalia o instrumento normativo e suas regras de decisão, considerando limiares, sensibilidade e casos compensatórios; nele se situam S4, S5 e S6. O Protocolo EC complementa ambos os blocos como auditoria de plausibilidade clínica interna.

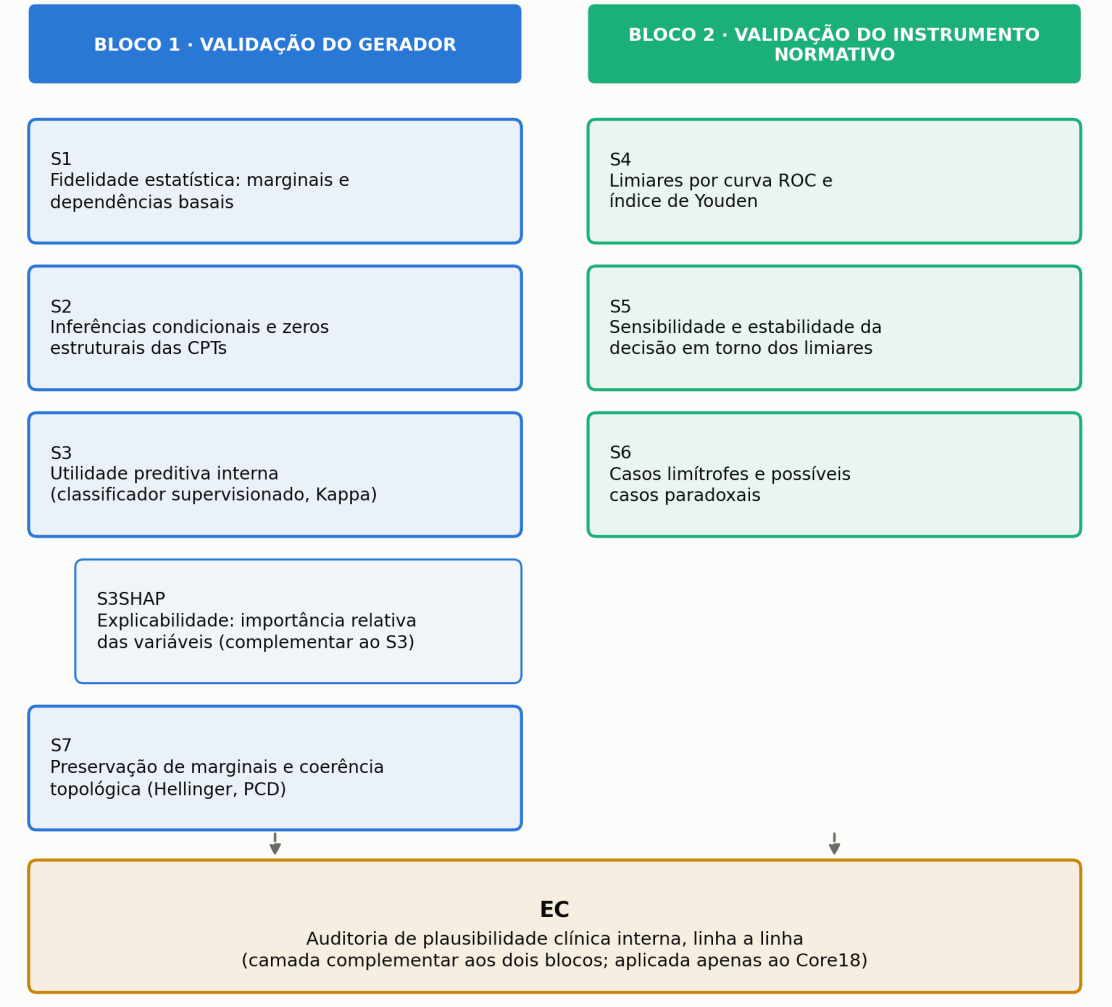


Figura 3 – Síntese dos protocolos de validação interna aplicados aos modelos Core11 e Core18.

Fonte: Produção dos autores, 2026

Tabela 3 – Protocolos de validação utilizados na pesquisa

Protocolo	**Finalidade**
S1	Avaliar fidelidade estatística, marginais e dependências fundamentais.
S2	Testar inferências condicionais e zeros estruturais definidos nas CPTs.
S3	Avaliar utilidade preditiva interna por modelo supervisionado e métricas de classificação.
S3SHAP	Examinar explicabilidade e importância relativa das variáveis.
S4	Avaliar limiares por curva ROC e índice de Youden.
S5	Avaliar sensibilidade e estabilidade da decisão em torno dos limiares.
S6	Auditar casos limítrofes e possíveis casos paradoxais.
S7	Verificar preservação de marginais e coerência topológica por Hellinger e PCD.
EC	Auditar plausibilidade clínica interna linha a linha por edit checks.

Fonte: Produção dos autores, 2026

3.10.1 Validação Estrutural

A validação estrutural busca verificar se a implementação preserva as regras fundamentais do modelo. O S1 testa distribuições e dependências basais, enquanto o S2 verifica inferências condicionais esperadas. No Core18, o S2 foi ampliado para contemplar os novos nós e suas CPTs.

3.10.2 Validação Estatística e Topológica

A validação estatística e topológica avalia se o dataset gerado preserva as propriedades esperadas da rede. A Distância de Hellinger foi utilizada para comparar distribuições marginais, enquanto a Diferença de Correlação Pareada (PCD) avaliou a preservação da estrutura de dependência entre variáveis Goncalves et al. (2020), Emam et al. (2022).

O protocolo S7 é particularmente relevante para dados sintéticos porque avalia se o gerador mantém coerência multivariada, e não apenas frequências isoladas. Isso é essencial em saúde, onde relações entre variáveis podem ser mais importantes do que distribuições univariadas.

3.10.3 Validação Preditiva e Explicativa

O protocolo S3 avalia se a decisão de alta é aprendível a partir das variáveis sintéticas. Para isso, utiliza-se um classificador externo em regime TSTS, com métricas como acurácia, F1 e Kappa. O objetivo não é demonstrar validade clínica externa, mas verificar se o dataset possui sinal analítico coerente e não colapsa em ruído Rankin et al. (2020), Hittmeir, Ekelhart e Mayer (2019), Hernandez et al. (2025). A estatística Kappa foi utilizada como medida de concordância categórica entre rótulos esperados e preditos, com interpretação baseada na referência clássica de Landis e Koch Landis e Koch (1977).

O protocolo S3SHAP complementa essa análise ao examinar a importância relativa das variáveis. Essa etapa é útil para verificar se o modelo preditivo atribui relevância a variáveis compatíveis com a estrutura normativa e com a distribuição do dataset. Contudo, a interpretação do SHAP deve considerar que importância preditiva e peso normativo não são conceitos equivalentes. Assim, divergências entre ranking explicativo e pesos normativos são tratadas como achados analíticos relevantes, especialmente quando revelam que o classificador aprendeu padrões dominantes do universo sintético que não coincidem integralmente com a hierarquia clínica esperada.

3.10.4 Validação Clínica Interna

A validação clínica interna é realizada principalmente pelos protocolos S6 e EC. O S6 avalia casos de zona de borda e verifica se há perfis paradoxais aprovados. O EC, por sua vez, audita combinações clinicamente pouco plausíveis em todo o dataset.

Essa camada não transforma o modelo em ferramenta clínica assistencial, mas fortalece sua interpretação como gerador sintético auditável. Ao registrar violações, a metodologia explicita os limites do gerador e evita que a coerência estatística global seja confundida com plausibilidade clínica individual plena. A EC-01, por exemplo, audita a combinação entre Apgar deprimido e sono adequado, pois a presença de gravidade neonatal importante torna clinicamente questionável a simultânea classificação de sono como adequado; essa regra é tratada como consenso clínico e reforçada por diretrizes de reanimação e avaliação neonatal, sem alterar CPTs nem acionar reamostragem automática nesta versão Almeida e Guinsburg (2026).

3.11 Experimentos Realizados

Foram consideradas duas execuções principais, ambas com $n = 10000$, uma para o Core11 e outra para o Core18. A escolha do mesmo tamanho amostral facilita a comparação entre as versões. A execução oficial do Core11 corresponde a `exec_20260706_135341`; execuções posteriores com menor número de amostras foram tratadas como testes operacionais e não foram utilizadas como referência da dissertação. A execução oficial do Core18 corresponde à versão pós-incorporação da EC-01 e correção de timestamp, registrada como `exec_20260708_141901`.

Tabela 4 – Execuções principais analisadas na dissertação

Experimento	**Modelo**	**n**	**Execução**
`01_Core11_Baseline`	Core11	10000	`exec_20260706_135341`
`01_Core18_Baseline`	Core18	10000	`exec_20260708_141901`

Fonte: Produção dos autores, 2026

A execução Core11 gerou um dataset com 10000 linhas e 13 colunas. A execução Core18 gerou um dataset com 10000 linhas e 20 colunas. Em ambos os casos, foram produzidos arquivos de métricas, gráficos, relatório de ata, metadados de execução e informações de ambiente, permitindo reprodutibilidade e análise posterior.

3.12 Comparação Metodológica Core11–Core18

A comparação entre Core11 e Core18 não deve ser interpretada apenas como diferença de desempenho, mas como evidência da capacidade de expansão da metodologia. O Core11 demonstrou que a arquitetura inicial funcionava; o Core18 mostrou que o mesmo pipeline poderia ser ampliado para um domínio clínico mais rico.

A Tabela 5 apresenta uma síntese metodológica das execuções oficiais e indica que o Core18 manteve desempenho estatístico e topológico satisfatório após a expansão, mas também evidenciou que a coerência probabilística global não garante, sozinha, plausibilidade clínica

individual em todas as linhas sintéticas. Essa conclusão é central para a interpretação metodológica da pesquisa. A interpretação detalhada dos resultados é retomada no Capítulo 5

Tabela 5 – Síntese comparativa dos resultados metodológicos

Critério	**Core11**	**Core18**	**Leitura**
Variáveis clínicas	11	18	Expansão do domínio clínico.
S1	7/7	7/7	Fidelidade estatística preservada nas execuções oficiais.
S2	7/7	14/14	Novas regras condicionais validadas.
Kappa médio (S3)	0,9445	0,9209	Concordância quase perfeita no regime TSTS.
Casos paradoxais (S6)	0	0	Nenhum caso paradoxal detectado.
S7 Hellinger	11/11	18/18	Marginais preservadas.
S7 PCD MAD	0,0088	0,0097	Boa coerência topológica.
EC	Não aplicado	36,9% de linhas com violação	Auditoria de plausibilidade individual; 2/14 regras sem violação.

Fonte: Produção dos autores, 2026

Essa mudança sugere que o Core18 tornou o processo de classificação mais conservador para a concessão de Alta Segura. A interpretação mais adequada não é que o modelo tenha se tornado apenas mais severo, mas que passou a capturar mais situações intermediárias, deslocando parte dos registros para Alta com Recomendação.

3.13 Reprodutibilidade e Organização dos Artefatos

A reprodutibilidade foi considerada parte da metodologia. Cada execução experimental foi organizada em diretórios contendo datasets, métricas, gráficos, relatórios e informações de ambiente. Quando disponível, também foram registrados o hash do algoritmo e a versão do Python utilizada.

Na execução oficial do Core18, os artefatos foram consolidados com timestamp único de execução (`20260708_1418`), utilizado para nomear dataset, métricas e gráficos, incluindo os protocolos S4, S5 e S6. Essa padronização evita a fragmentação de artefatos por múltiplos sufixos temporais e melhora a rastreabilidade entre arquivo CSV, métricas estruturadas, figuras e ata técnica.

3.14 Delimitações Metodológicas

A primeira delimitação é que o modelo foi avaliado apenas em ambiente de simulação. Não houve implantação em hospital, integração com prontuário eletrônico, avaliação prospectiva, uso por equipe assistencial ou comparação com decisões clínicas reais.

A segunda delimitação é que as probabilidades foram construídas por abordagem knowledge-driven. Embora essa estratégia seja adequada ao problema de cold start, ela não substitui calibração empírica futura com dados reais, caso estes venham a estar disponíveis de forma ética e regulatória.

A terceira delimitação refere-se ao Protocolo EC. No Core18, o EC atua como auditoria pós-geração, e não como mecanismo ativo de filtragem. Portanto, linhas com violações podem existir no dataset final, sendo quantificadas e interpretadas como indicadores dos limites de plausibilidade individual do gerador. A EC-01 segue a mesma lógica: embora sua formulação operacional indique uma combinação a ser rejeitada do ponto de vista clínico-metodológico, essa rejeição é registrada como auditoria, sem remoção automática da linha sintética.

Por fim, a dissertação encerra sua contribuição experimental no Core18. A expansão para Core25 é reconhecida como continuidade possível, mas não é tratada como modelo implementado e validado no escopo final deste trabalho.

3.15 Síntese do Capítulo

Este capítulo apresentou a metodologia computacional para geração, expansão e validação de dados sintéticos neonatais por Redes Bayesianas. A proposta parte de uma base de conhecimento clínico, estrutura variáveis e dependências em um DAG, parametriza CPTs, gera registros sintéticos, calcula escore e decisão de alta, e avalia o resultado por um conjunto de protocolos complementares.

A evolução Core11–Core18 demonstra a principal contribuição metodológica da pesquisa: não apenas gerar um dataset sintético, mas construir um pipeline reprodutível de modelagem, geração e validação. O Core11 funcionou como prova inicial da arquitetura, enquanto o Core18 demonstrou expansão do domínio clínico, preservação de propriedades estatísticas e topológicas, e necessidade de auditoria de plausibilidade clínica individual por meio do Protocolo EC.

4

Trabalhos Relacionados

Este capítulo posiciona a proposta desta dissertação em relação à literatura sobre Inteligência Artificial aplicada à neonatologia, geração de dados sintéticos em saúde, modelos probabilísticos interpretáveis e estratégias de validação em cenários de indisponibilidade de dados reais. Diferentemente da Fundamentação Teórica, cujo objetivo é apresentar os conceitos que sustentam o trabalho, este capítulo busca identificar como a literatura existente aborda problemas semelhantes e quais lacunas permanecem abertas para a proposta desenvolvida nesta pesquisa Kwok et al. (2022), Goncalves et al. (2020), Murtaza et al. (2023), Santos, Silva e Silva (2026).

A análise é organizada em quatro eixos. O primeiro discute modelos preditivos em neonatologia, destacando o predomínio de estudos voltados à mortalidade, morbidades, sepse e risco clínico Kwok et al. (2022), Batista et al. (2021), Bernardino et al. (2024). O segundo aborda métodos de geração de dados sintéticos em saúde, com atenção às abordagens orientadas a dados e seus limites em privacidade e plausibilidade clínica Goncalves et al. (2020), Gonzales, Guruswamy e Smith (2023), Giuffrè e Shung (2023), Murtaza et al. (2023), Nisevic, Milojevic e Spajic (2025), Boni, Junior e Costa (2025). O terceiro examina o papel de redes bayesianas e modelos orientados por conhecimento como alternativas interpretáveis Kaur et al. (2021), Flores et al. (2023), Miletic e Sariyar (2026). O quarto discute estratégias de validação de dados sintéticos quando não há base real disponível para comparação direta Goncalves et al. (2020), Emam et al. (2022), Hernandez et al. (2025), Hernandez et al. (2022), Alaa et al. (2022), Chundawat et al. (2022). Ao final, sintetizam-se as lacunas que justificam a abordagem proposta.

4.1 Estratégia de Levantamento e Organização da Literatura

A organização dos trabalhos relacionados foi conduzida como uma revisão estruturada da literatura, inspirada nas etapas de planejamento, condução e análise propostas por Kitchenham (2004). O objetivo foi organizar de forma transparente as fontes utilizadas para posicionar a

proposta desta dissertação em quatro eixos: Inteligência Artificial em neonatologia, geração de dados sintéticos em saúde, Redes Bayesianas e modelagem orientada por conhecimento, e estratégias de validação de dados sintéticos em cenários de ausência de dados reais.

Na etapa de planejamento, foram definidas três questões orientadoras:

- **Q1:** Quais técnicas computacionais vêm sendo utilizadas para a geração e o aumento de dados sintéticos tabulares na área da saúde?
- **Q2:** Como a literatura especializada realiza a avaliação de qualidade, fidelidade, utilidade e privacidade de bases de dados sintéticas?
- **Q3:** Qual é o panorama atual da aplicação de Inteligência Artificial e modelos preditivos no contexto da neonatologia e da alta hospitalar?

Quadro 1 – Lista de palavras-chave utilizadas no levantamento

Termo em português	**Termo em inglês**
Dados sintéticos	Synthetic data
Aumento de dados	Data augmentation
Aprendizado de máquina	Machine learning
Rede Bayesiana	Bayesian network
Aprendizado profundo	Deep learning
Neonatologia	Neonatology / neonatal
Dados de saúde	Health data
Alta hospitalar	Patient discharge / hospital discharge
Alta segura neonatal	Safe neonatal discharge
Privacidade	Privacy
Fidelidade	Fidelity
Utilidade	Utility

Fonte: Produção dos autores, 2026

As buscas foram conduzidas nas bases Scopus, PubMed/MEDLINE, Web of Science, IEEE Xplore e LILACS, complementadas por busca manual e snowballing para inclusão de diretrizes clínicas, normativas e documentos oficiais relevantes ao domínio neonatal.

Quadro 2 – Bases de pesquisa utilizadas no levantamento

Base de pesquisa	**Endereço eletrônico**
Scopus	<https://www.scopus.com>
PubMed / MEDLINE	<https://pubmed.ncbi.nlm.nih.gov>
Web of Science	<https://www.webofscience.com>
IEEE Xplore	<https://ieeexplore.ieee.org>
LILACS	<https://lilacs.bvsalud.org>

Fonte: Produção dos autores, 2026

A string geral de busca combinou os três eixos centrais da pesquisa:

```
("synthetic data"OR "data augmentation") AND ("machine learning"OR "Bayesian
network"OR "deep learning") AND ("neonatal"OR "health data"OR "patient
discharge")
```

Quadro 3 – Critérios de inclusão e exclusão

Tipo	**Critério**
CI1	Estudos primários, revisões sistemáticas ou revisões de escopo.
CI2	Disponibilidade do texto completo.
CI3	Publicação em inglês, português ou espanhol.
CI4	Relação direta com avaliação de dados sintéticos, Inteligência Artificial em saúde ou neonatologia, Redes Bayesianas ou alta segura neonatal.
CE1	Registros duplicados entre as bases consultadas.
CE2	Estudos sem relação direta com dados tabulares, neonatologia, saúde digital ou validação de dados sintéticos.
CE3	Estudos sem contribuição metodológica ou clínica clara para os eixos da dissertação.

Fonte: Produção dos autores, 2026

Quadro 4 – Quantidade de trabalhos encontrados e selecionados por base de dados

Base de pesquisa / origem	**Encontrados (acervo bruto)**	**Selecionados (amostra final)**
Scopus	75	16
PubMed / MEDLINE	60	12
Web of Science	45	8
IEEE Xplore	20	4
LILACS	11	2
Busca manual / Snowballing	12	12
Total	**223**	**54**

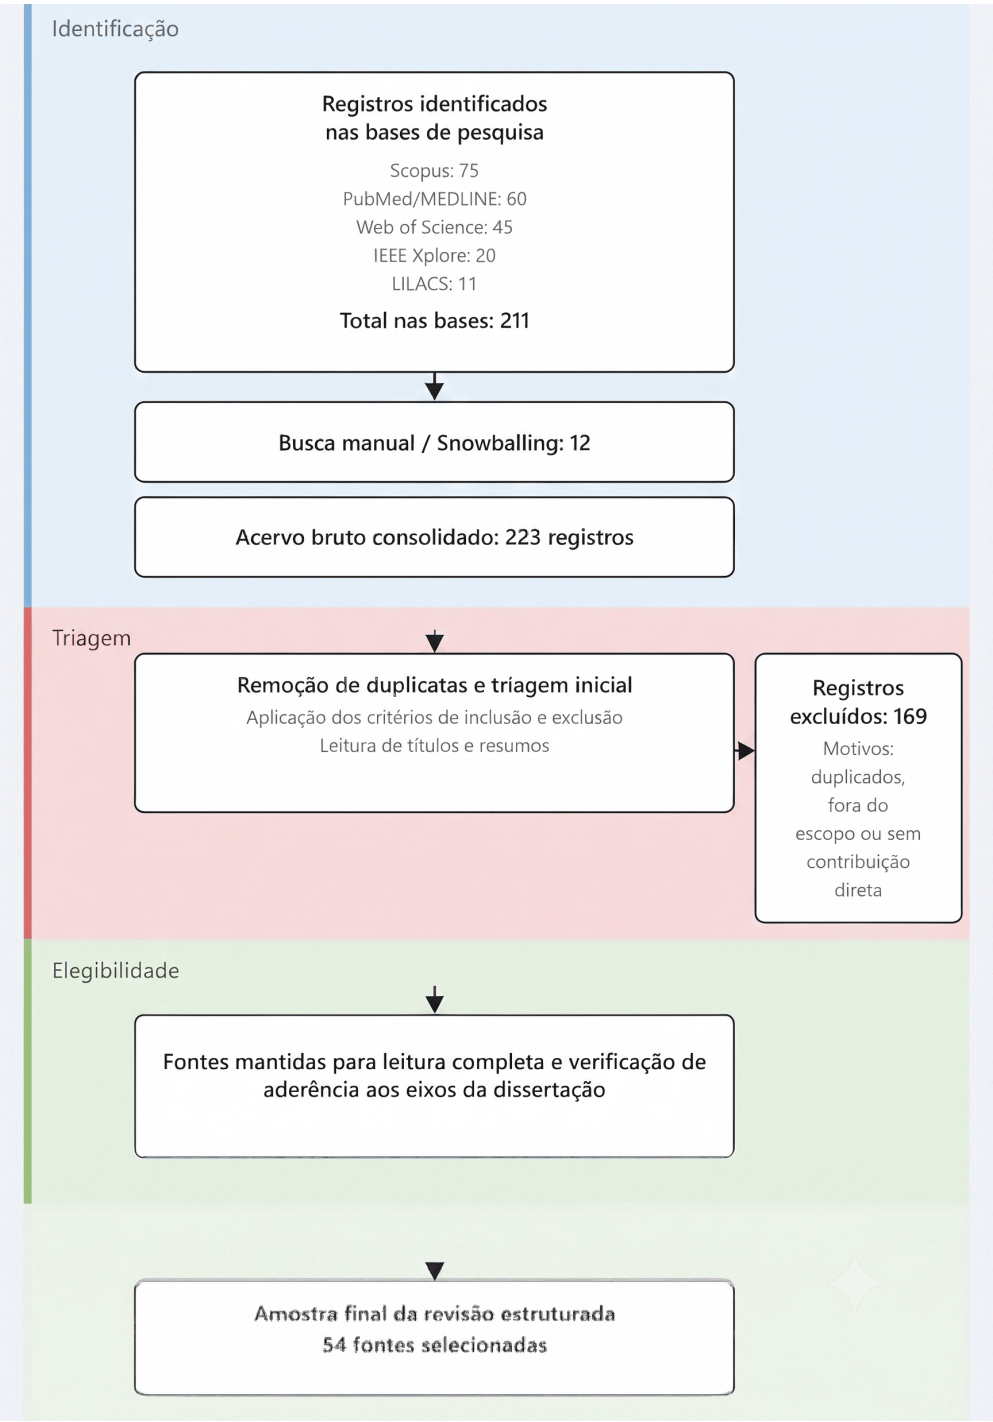
Nota: a busca manual e o snowballing incluíram diretrizes, normativas e documentos oficiais relevantes ao domínio clínico da alta neonatal.

Fonte: Produção dos autores, 2026

As buscas foram conduzidas nas bases Scopus, PubMed/MEDLINE, Web of Science, IEEE Xplore e LILACS, complementadas por busca manual e snowballing para inclusão de diretrizes clínicas, normativas e documentos oficiais relevantes ao domínio neonatal.

A Figura 4 apresenta o fluxo de identificação, triagem, elegibilidade e síntese das fontes utilizadas na revisão estruturada.

Figura 4 – Fluxograma das etapas de seleção das fontes da revisão estruturada



Fonte: Produção do autor (2026).

As fontes selecionadas foram analisadas segundo sua contribuição para: (i) caracterização do problema clínico; (ii) métodos computacionais empregados; (iii) dependência de dados reais; (iv) estratégias de validação; e (v) lacunas em relação à geração de dados sintéticos tabulares, interpretáveis e orientados por conhecimento para alta segura neonatal.

Como ameaça à validade do levantamento, reconhece-se a possibilidade de viés de seleção associado às bases consultadas, aos termos utilizados na string de busca e aos critérios de

inclusão e exclusão. Além disso, estudos publicados em veículos não indexados ou em idiomas diferentes dos considerados podem não ter sido recuperados. Ainda assim, a combinação entre bases multidisciplinares, bases da saúde e busca manual de diretrizes clínicas permitiu compor um conjunto de referências adequado ao posicionamento metodológico da dissertação.

4.1.1 Síntese do Levantamento

A organização das fontes evidenciou que os estudos relacionados ao problema desta dissertação se distribuem em quatro grupos principais. O primeiro reúne trabalhos sobre Inteligência Artificial em neonatologia, nos quais predominam modelos preditivos orientados por dados reais e voltados a desfechos como mortalidade, sepse, morbidades e risco clínico. Embora esses estudos demonstrem o potencial da IA no cuidado neonatal, eles não tratam diretamente a alta segura como problema multidimensional de transição do cuidado.

O segundo grupo concentra estudos sobre geração de dados sintéticos em saúde. Essa literatura discute métodos generativos, aumento de dados, privacidade, utilidade e fidelidade estatística, mas usualmente parte da existência de bases reais para treinamento, comparação ou validação. Assim, permanece uma limitação importante para cenários de *cold start*, nos quais dados clínicos reais ainda não estão disponíveis ou não podem ser utilizados.

O terceiro grupo envolve Redes Bayesianas, sistemas de apoio à decisão e abordagens orientadas por conhecimento. Esses trabalhos sustentam a escolha de modelos probabilísticos interpretáveis, capazes de representar dependências condicionais e incorporar conhecimento de domínio. No entanto, ainda são escassas as aplicações voltadas especificamente à geração de dados sintéticos para alta segura neonatal.

O quarto grupo reúne estudos e frameworks de avaliação de dados sintéticos. A literatura aponta que a qualidade de bases sintéticas deve ser avaliada por múltiplas dimensões, incluindo fidelidade estatística, utilidade analítica, risco de privacidade e plausibilidade clínica. Essa constatação fundamenta a necessidade de protocolos complementares de validação interna, especialmente quando não há base real disponível para comparação direta.

Dessa forma, o levantamento reforça a lacuna investigada nesta dissertação: a ausência de abordagens que integrem alta segura neonatal, geração de dados totalmente sintéticos, modelagem orientada por conhecimento, Redes Bayesianas interpretáveis e validação multidimensional em cenário de indisponibilidade inicial de dados reais. Essa lacuna orienta a organização das seções seguintes, que discutem separadamente cada um desses eixos e, ao final, posicionam a contribuição proposta.

4.2 Modelos de Inteligência Artificial em Neonatologia

A aplicação de técnicas de Inteligência Artificial e Aprendizado de Máquina em neonatologia tem crescido nos últimos anos, especialmente em tarefas de predição de mortalidade, identificação de morbidades, estratificação de risco e apoio à priorização de cuidados intensivos Kwok et al. (2022), Batista et al. (2021). Esses trabalhos evidenciam que modelos computacionais podem capturar relações não lineares entre variáveis maternas, perinatais e neonatais, oferecendo desempenho promissor em cenários nos quais métodos estatísticos tradicionais podem ser limitados.

Em estudos baseados em grandes bases populacionais, algoritmos supervisionados como Random Forest, Support Vector Machines, redes neurais e métodos de *gradient boosting* têm sido empregados para predizer desfechos neonatais relevantes. No contexto brasileiro, por exemplo, bases administrativas e epidemiológicas têm permitido a construção de modelos de predição de mortalidade neonatal com alto desempenho discriminativo, mostrando a utilidade de dados rotineiros de saúde para apoiar estratégias de vigilância e priorização Batista et al. (2021).

Apesar desses avanços, a literatura em IA neonatal tende a se concentrar em desfechos como mortalidade, sepse, morbidades específicas e risco em unidades neonatais Kwok et al. (2022), Batista et al. (2021), Bernardino et al. (2024). A alta hospitalar neonatal, por sua vez, apresenta características diferentes: trata-se de uma decisão de transição do cuidado, multidimensional e dependente da integração entre estabilidade clínica, testagens, vacinação, preparo familiar e seguimento na rede de atenção Araujo et al. (2023), Queiroz et al. (2019), Lucchese et al. (2024), Silva et al. (2024a). Assim, modelos voltados exclusivamente à predição de mortalidade ou morbidade não cobrem integralmente a lógica assistencial da alta segura.

Outro ponto recorrente é a dependência de dados reais. Modelos preditivos de alto desempenho usualmente exigem bases extensas, rotuladas e representativas. Em instituições ou projetos que ainda não dispõem dessas bases, surge o problema de *cold start*, no qual a ausência de dados suficientes impede o desenvolvimento inicial de soluções computacionais Chen et al. (2021), Nisevic, Milojevic e Spajic (2025). Esse desafio é particularmente importante em saúde, pois mesmo bases existentes podem ter uso restrito por governança, privacidade e legislação.

Portanto, a literatura de IA neonatal demonstra o potencial de modelos computacionais, mas também revela uma lacuna: ainda são limitadas as abordagens que tratam a alta segura neonatal como problema multidimensional e que, simultaneamente, ofereçam uma estratégia para desenvolvimento em cenário de ausência de dados reais disponíveis Kwok et al. (2022), Araujo et al. (2023), Silva et al. (2024a), Santos, Silva e Silva (2026).

4.3 Geração de Dados Sintéticos em Saúde

A geração de dados sintéticos em saúde tem sido proposta como alternativa para pesquisa, desenvolvimento de algoritmos, simulação e compartilhamento controlado de informações, especialmente diante das restrições éticas e legais associadas a prontuários reais Goncalves et al. (2020), Gonzales, Guruswamy e Smith (2023), Giuffrè e Shung (2023), Hernandez et al. (2022), Murtaza et al. (2023). De modo geral, a literatura distingue abordagens totalmente sintéticas, parcialmente sintéticas e híbridas, cada uma com diferentes implicações para privacidade, utilidade e risco de reidentificação Goncalves et al. (2020), Hernandez et al. (2022), Yale et al. (2020), Jordon et al. (2022), Boni, Junior e Costa (2025).

Grande parte das abordagens contemporâneas é orientada a dados. Métodos como GANs, VAEs e modelos generativos baseados em aprendizado profundo buscam aprender padrões diretamente de bases reais para produzir novos registros com propriedades estatísticas semelhantes às originais Murtaza et al. (2023), Nisevic, Milojevic e Spajic (2025). Essas técnicas podem alcançar alta similaridade estatística, mas dependem de uma base real inicial, o que não resolve integralmente o problema de *cold start*.

Estudos sobre síntese de dados clínicos também enfatizam que a utilidade de uma base sintética depende do uso pretendido. Em alguns cenários, a avaliação prioriza preservação de distribuições e dependências; em outros, mede-se o desempenho de tarefas de aprendizado de máquina treinadas com dados sintéticos. Essa literatura reforça que métricas isoladas são insuficientes e que a avaliação deve combinar fidelidade estatística, utilidade por tarefa, riscos de privacidade e interpretação do domínio Emam et al. (2022), Hernandez et al. (2025), Kaabachi et al. (2025).

Trabalhos recentes em dados sintéticos tabulares reforçam esse movimento de avaliação multidimensional. De Boni et al. sistematizam métodos de aumento de dados tabulares e propõem uma leitura taxonômica centrada em utilidade, fidelidade e privacidade; em continuidade aplicada, o Hy-Synergy explora geração tabular guiada por diagnóstico local em bases clínicas pequenas e sensíveis Boni, Junior e Costa (2025), Boni, Junior e Costa (2026). Propostas como TabSynDex e métricas de fidelidade amostral também indicam que a qualidade sintética deve ser examinada em múltiplas escalas, do registro individual à estrutura distribucional global Alaa et al. (2022), Chundawat et al. (2022).

Além disso, a literatura aponta riscos importantes em dados sintéticos gerados a partir de bases reais. Modelos generativos podem memorizar registros, preservar padrões sensíveis ou gerar instâncias muito próximas de indivíduos do conjunto original, criando riscos de inferência de pertinência, inferência de atributos ou reidentificação Tucker et al. (2020), Yale et al. (2020), Murtaza et al. (2023). Esses riscos exigem avaliação cuidadosa, pois dados sintéticos não devem ser considerados automaticamente anônimos ou seguros apenas por terem sido gerados artificialmente.

Outro desafio é a plausibilidade clínica. Em saúde, uma base sintética não precisa apenas preservar distribuições marginais ou correlações globais; ela também deve evitar combinações biologicamente improváveis ou clinicamente incoerentes. Modelos puramente orientados a dados podem aprender correlações sem incorporar restrições explícitas de domínio, o que pode resultar em registros sintéticos com baixa interpretabilidade clínica Goncalves et al. (2020), Giuffrè e Shung (2023), Nisevic, Milojevic e Spajic (2025).

Esses pontos indicam que a geração sintética em saúde deve ser avaliada por múltiplas dimensões, incluindo fidelidade estatística, utilidade analítica, risco de privacidade e plausibilidade clínica Goncalves et al. (2020), Emam et al. (2022), Hernandez et al. (2025), Kaabachi et al. (2025), Murtaza et al. (2023), Hernandez et al. (2022). A presente dissertação se insere nesse debate ao propor uma alternativa que não aprende a partir de uma base real, mas constrói o gerador por conhecimento clínico estruturado.

4.4 Redes Bayesianas e Modelagem Orientada por Conhecimento

Redes Bayesianas têm sido utilizadas em saúde por sua capacidade de representar dependências condicionais entre variáveis, apoiar inferência probabilística e incorporar conhecimento especializado de forma interpretável Kaur et al. (2021), Flores et al. (2023). Diferentemente de modelos *black-box*, sua estrutura em Grafo Direcionado Acíclico permite que especialistas examinem quais variáveis foram incluídas, quais dependências foram assumidas e como a incerteza é propagada.

Na geração de dados sintéticos, Redes Bayesianas podem atuar como modelos geradores: uma vez definida a estrutura e parametrizadas as distribuições, a rede pode amostrar registros artificiais compatíveis com as dependências probabilísticas especificadas Goncalves et al. (2020), Kaur et al. (2021). Essa característica é especialmente útil em domínios nos quais a interpretabilidade e a coerência causal são relevantes. Revisões recentes sobre dados longitudinais e temporais em saúde também reforçam que a avaliação de realismo clínico não se limita à similaridade marginal, exigindo atenção a estrutura, sequência e plausibilidade contextual Miletic e Sariyar (2026).

Entretanto, muitas aplicações de Redes Bayesianas em síntese de dados ainda são orientadas por dados, isto é, aprendem estrutura ou parâmetros a partir de uma base real. Nesses casos, embora a interpretabilidade seja maior do que em algumas arquiteturas de aprendizado profundo, permanece a dependência de dados reais para treinamento e calibração Goncalves et al. (2020), Murtaza et al. (2023). Essa dependência limita seu uso em cenários de *cold start*.

A abordagem *knowledge-driven* desloca essa lógica. Nela, a estrutura da rede, as variáveis, as dependências e as probabilidades são derivadas de conhecimento clínico, literatura, documentos

normativos e curadoria de especialistas Flores et al. (2023), Santos, Silva e Silva (2026). Essa estratégia não elimina incertezas, mas torna as premissas explícitas e auditáveis, permitindo revisar arestas, CPTs e regras de plausibilidade.

No contexto da alta segura neonatal, essa característica é particularmente relevante. O domínio envolve relações clínicas conhecidas, como o papel da idade gestacional, do peso ao nascer, da vitalidade, da estabilidade respiratória, da amamentação e das triagens na prontidão para alta Sociedade Brasileira de Pediatria (2021), Araujo et al. (2023), Silva et al. (2024a). Uma Rede Bayesiana orientada por conhecimento permite representar essas relações de forma explícita, sem depender inicialmente de uma coorte real de pacientes.

Assim, a literatura sobre Redes Bayesianas sustenta a escolha metodológica desta dissertação, mas também evidencia sua lacuna específica: ainda são escassos os modelos orientados por conhecimento voltados à geração de dados sintéticos para alta segura neonatal, com validação explícita de fidelidade probabilística, topológica e plausibilidade clínica auditável Kaur et al. (2021), Flores et al. (2023), Goncalves et al. (2020), Santos, Silva e Silva (2026).

4.5 Validação de Dados Sintéticos na Ausência de Dados Reais

A validação de dados sintéticos em saúde costuma envolver a comparação entre a base sintética e uma base real de referência. Quando essa base está disponível, é possível avaliar similaridade de distribuições, preservação de correlações, desempenho preditivo em regimes de treinamento e teste cruzados, além de riscos de privacidade e proximidade entre registros sintéticos e reais Goncalves et al. (2020), Emam et al. (2022), Hernandez et al. (2025), Rankin et al. (2020), Hernandez et al. (2022), Murtaza et al. (2023).

Entretanto, a premissa desta dissertação é justamente a ausência de dados reais acessíveis no momento inicial da modelagem. Nesse cenário, métricas que dependem de comparação direta com uma coorte real não podem ser aplicadas como validação principal. Isso cria um desafio metodológico: avaliar um gerador sintético sem recorrer ao padrão comparativo usual entre sintético e real Goncalves et al. (2020), Murtaza et al. (2023), Santos, Silva e Silva (2026).

A literatura recomenda que a avaliação de dados sintéticos considere, sempre que possível, dimensões complementares de fidelidade, utilidade e privacidade Goncalves et al. (2020), Emam et al. (2022), Hernandez et al. (2025), Giuffrè e Shung (2023), Kaabachi et al. (2025), Murtaza et al. (2023). Em um cenário sem dados reais, parte dessas dimensões precisa ser adaptada para verificar se o gerador preserva as propriedades que ele próprio declara implementar: marginais esperadas, inferências condicionais, dependências topológicas e regras de plausibilidade.

Nesse sentido, a validação interna não deve ser confundida com validação clínica externa. Ela permite verificar se o modelo executado respeita suas próprias premissas probabilísticas e se a base gerada possui sinal analítico coerente, mas não demonstra, por si só, capacidade de

generalização para pacientes reais. Essa distinção é essencial para interpretar corretamente dados sintéticos em contexto de *cold start* Goncalves et al. (2020), Nisevic, Milojevic e Spajic (2025), Santos, Silva e Silva (2026).

A presente dissertação propõe uma estratégia de validação interna composta por protocolos complementares. Esses protocolos avaliam fidelidade estatística, inferência condicional, utilidade preditiva em regime *Train on Synthetic, Test on Synthetic* (TSTS), explicabilidade, sensibilidade de limiares, casos-limite, fidelidade topológica e auditoria por *edit checks*. Tal abordagem não substitui validação externa futura, mas oferece um caminho auditável para avaliar um gerador sintético em cenário de ausência de dados reais Goncalves et al. (2020), Emam et al. (2022), Hernandez et al. (2025).

4.6 Síntese Comparativa dos Trabalhos Relacionados

A Tabela 6 sintetiza o posicionamento dos principais trabalhos e eixos da literatura em relação à proposta desta dissertação. A comparação privilegia dimensões metodológicas diretamente relacionadas ao problema de pesquisa: domínio de aplicação, estratégia computacional, dependência de dados reais, forma de validação e lacuna remanescente para a geração de dados sintéticos voltada à alta segura neonatal Kwok et al. (2022), Goncalves et al. (2020), Kaur et al. (2021), Araujo et al. (2023), Santos, Silva e Silva (2026).

Tabela 6 – Síntese comparativa dos trabalhos relacionados

Referência	**Foco principal**	**Estratégia metodológica**	**Validação e dados**	**Lacuna em relação à proposta**
Kwok et al. (2022)	Aplicações de Inteligência Artificial em medicina neonatal.	Revisão do potencial de modelos computacionais para predição, monitoramento, estratificação de risco e apoio à decisão em neonatologia.	Discute aplicações dependentes de dados clínicos reais e validação em tarefas neonatais específicas.	Não propõe geração de dados sintéticos, nem trata a alta segura neonatal como problema gerador multidimensional em cenário de ausência de dados reais.

Continuação da Tabela 6

Referência	**Foco principal**	**Estratégia metodológica**	**Validação e dados**	**Lacuna em relação à proposta**
Batista et al. (2021)	Predição de mortalidade neonatal com dados rotineiros de saúde.	Modelos supervisionados de Aprendizado de Máquina aplicados a bases populacionais e administrativas.	Validação preditiva baseada em dados reais, com métricas de desempenho discriminativo.	Foco em mortalidade neonatal, não em transição de cuidado ou prontidão para alta; depende de grande base real rotulada.
Araujo et al. (2023)	Critérios relacionados à alta hospitalar segura do recém-nascido.	Revisão integrativa voltada à identificação de critérios clínicos e assistenciais relevantes para a alta neonatal.	Base de evidência para organizar dimensões da alta segura, incluindo estabilidade clínica, triagens, orientações e continuidade do cuidado.	Não propõe modelo computacional gerador, nem avalia dados sintéticos ou inferência probabilística.
Silva et al. (2024a)	Aplicativo para alta segura do recém-nascido.	Desenvolvimento tecnológico e sistematização de requisitos para apoiar a transição do cuidado neonatal.	Estrutura critérios e requisitos de aplicação em saúde, com foco assistencial e educacional.	Contribui para o domínio clínico, mas não implementa geração sintética, Rede Bayesiana ou validação estatística de coortes artificiais.
Silva et al. (2024b)	Requisitos para construção de aplicação voltada à alta e transição do cuidado.	Levantamento de requisitos e organização de funcionalidades esperadas para suporte tecnológico à alta neonatal.	Apoia a definição de necessidades informacionais e assistenciais do domínio.	Não aborda síntese de dados, ausência de dados reais, validação interna de geradores ou modelagem probabilística.

Continuação da Tabela 6

Referência	**Foco principal**	**Estratégia metodológica**	**Validação e dados**	**Lacuna em relação à proposta**
Souza e Brandão (2023)	Recomendações para profissionais de saúde sobre alta segura do recém-nascido.	Sistematização de recomendações assistenciais e educativas destinadas à prática profissional.	Fortalece a dimensão normativa e operacional da alta segura.	Não formaliza as recomendações em uma arquitetura computacional auditável nem em um gerador de dados.
Sociedade Brasileira de Pediatria (2021)	Recomendações para alta hospitalar do recém-nascido termo potencialmente saudável.	Documento normativo com critérios clínicos e assistenciais para alta hospitalar neonatal.	Serve como referência de domínio para critérios de segurança, acompanhamento e orientação familiar.	Não é um trabalho computacional; precisa ser traduzido para variáveis, dependências, pesos e regras auditáveis.
Goncalves et al. (2020)	Geração e avaliação de dados sintéticos de pacientes.	Discussão metodológica sobre tipos de dados sintéticos, estratégias de geração e métricas de avaliação.	Enfatiza comparação com dados reais, utilidade analítica, similaridade e riscos de privacidade.	Fornece base conceitual, mas não resolve o problema quando não há coorte real disponível para treinamento ou validação direta.
Hernandez et al. (2022)	Geração de dados sintéticos tabulares em saúde.	Revisão sistemática de métodos, domínios, tipos de dados, estratégias de avaliação e desafios de síntese tabular.	Mostra predomínio de avaliações baseadas em bases reais de referência e métricas de fidelidade, utilidade e privacidade.	Não é específica para neonatologia ou alta segura; a validação costuma pressupor dados reais comparáveis.

Continuação da Tabela 6

Referência	**Foco principal**	**Estratégia metodológica**	**Validação e dados**	**Lacuna em relação à proposta**
Boni, Junior e Costa (2025)	Aumento de dados tabulares por IA.	Revisão sistemática e taxonomia de métodos para aumento de dados tabulares, com ênfase em utilidade, fidelidade e privacidade.	Organiza métricas e famílias de métodos aplicáveis a dados tabulares, incluindo cenários de escassez e desbalanceamento.	Não focaliza alta neonatal nem geração por Rede Bayesiana orientada por conhecimento; contribui como base de avaliação e taxonomia.
Boni, Junior e Costa (2026)	Geração sintética tabular guiada por diagnóstico local.	Framework modular para aumento de dados sensíveis e desbalanceados, com avaliação por utilidade, fidelidade e privacidade.	Avalia bases tabulares clínicas e não clínicas, com métricas como C2ST, JSD, ROC AUC e MIA.	Depende de bases reais de referência e atua como aumento de dados; difere da proposta desta dissertação, que gera dados neonatais por conhecimento em cenário de *cold start*.
Alaa et al. (2022)	Fidelidade amostral e auditoria de modelos generativos.	Propõe métricas em nível de amostra para avaliar fidelidade, diversidade e generalização de dados sintéticos.	Reforça a necessidade de auditar não apenas distribuições globais, mas também a qualidade de amostras individuais.	Não é específico para saúde neonatal nem para Redes Bayesianas; contribui para justificar a camada de auditoria linha a linha.
Chundawat et al. (2022)	Métrica unificada para avaliação de dados tabulares sintéticos.	Propõe o TabSynDex como índice composto para avaliar qualidade de dados tabulares gerados.	Discute a dificuldade de comparar geradores sintéticos por métricas isoladas.	A métrica não foi implementada nesta dissertação; sua contribuição é contextualizar a necessidade de avaliação multidimensional.

Continuação da Tabela 6

Referência	**Foco principal**	**Estratégia metodológica**	**Validação e dados**	**Lacuna em relação à proposta**
Murtaza et al. (2023)	Estado da arte da geração de dados sintéticos no domínio da saúde.	Revisão de métodos clássicos, modelos generativos, aplicações, riscos e desafios.	Discute utilidade, privacidade, fidelidade e limitações de técnicas contemporâneas.	Abrange o campo de forma ampla, mas não apresenta uma solução *knowledge-driven* neonatal sem uso de dados reais.
Chen et al. (2021)	Dados sintéticos em aprendizado de máquina para medicina e saúde.	Análise conceitual sobre oportunidades, aplicações e limites dos dados sintéticos em modelos de IA médica.	Discute dados sintéticos como alternativa para desenvolvimento e validação em saúde, com atenção a barreiras de privacidade e acesso.	Não propõe uma arquitetura geradora específica para alta neonatal nem validação interna em cenário de *cold start*.
Rajotte et al. (2022)	Dados sintéticos como viabilizadores de aplicações de Aprendizado de Máquina em medicina.	Discussão aplicada sobre uso de dados sintéticos para desenvolvimento, teste e compartilhamento em saúde.	Valoriza o potencial de reduzir barreiras de acesso a dados e apoiar fluxos de desenvolvimento de modelos.	Não focaliza alta segura neonatal, nem modelagem probabilística orientada por conhecimento clínico.
Jordon et al. (2022)	Fundamentos de dados sintéticos: definição, motivação e formas de geração.	Discussão conceitual sobre por que e como gerar dados sintéticos em diferentes domínios.	Apresenta princípios gerais de síntese, utilidade e privacidade.	É referência de base, mas não aborda o problema clínico neonatal nem uma validação específica para ausência de dados reais.

Continuação da Tabela 6

Referência	**Foco principal**	**Estratégia metodológica**	**Validação e dados**	**Lacuna em relação à proposta**
Pezoulas et al. (2024)	Ferramentas e métodos de código aberto para geração sintética em saúde.	Revisão de ferramentas, modelos e estratégias disponíveis para síntese de dados.	Analisa alternativas técnicas predominantemente dependentes de dados reais para aprendizagem de padrões.	Apoia a contextualização técnica, mas não substitui uma abordagem construída por conhecimento clínico em cenário de *cold start*.
Yale et al. (2020)	Geração e avaliação de dados sintéticos preservadores de privacidade.	Avaliação de dados sintéticos com atenção ao equilíbrio entre privacidade e utilidade.	Explora métricas de avaliação e riscos associados à proximidade entre dados sintéticos e reais.	Parte de dados reais como referência; não cobre geração totalmente independente de prontuários reais.
Kaabachi et al. (2025)	Métricas de privacidade e utilidade em dados sintéticos médicos.	Revisão de escopo sobre métricas usadas para avaliar dados sintéticos em saúde.	Reforça a necessidade de tratar privacidade e utilidade como dimensões simultâneas, e não como propriedades automáticas da síntese.	Não propõe gerador neonatal; sustenta o enquadramento crítico de avaliação multidimensional adotado nesta dissertação.
Tucker et al. (2020)	Dados sintéticos de alta fidelidade para avaliação de software de Aprendizado de Máquina em saúde.	Geração de dados sintéticos para apoiar testes e desenvolvimento de modelos de ML.	Avalia fidelidade e utilidade dos dados gerados em relação a dados clínicos de origem.	Mantém dependência de dados reais e não contempla alta segura neonatal nem regras clínicas de plausibilidade individual.

Continuação da Tabela 6

Referência	**Foco principal**	**Estratégia metodológica**	**Validação e dados**	**Lacuna em relação à proposta**
Giuffrè e Shung (2023)	Inovação, aplicações e privacidade de dados sintéticos em saúde.	Discussão crítica sobre benefícios, riscos e usos possíveis de dados sintéticos em contextos clínicos.	Enfatiza que dados sintéticos exigem avaliação de qualidade, privacidade e adequação ao uso.	Não propõe um pipeline validado para geração neonatal orientada por conhecimento e auditada por protocolos internos.
Nisevic, Milojevic e Spajic (2025)	Implicações legais e éticas do perfilamento de pacientes com dados sintéticos.	Análise de riscos jurídicos, éticos e regulatórios relacionados a dados sintéticos em medicina.	Discute limites da anonimização sintética e a necessidade de governança.	Reforça a motivação de privacidade, mas não apresenta solução técnica para geração sintética neonatal sem dados reais.
Kaur et al. (2021)	Uso de Redes Bayesianas para geração de dados sintéticos em saúde.	Modelo probabilístico gráfico capaz de representar dependências condicionais e gerar registros sintéticos interpretáveis.	Explora a capacidade das Redes Bayesianas como alternativa para síntese de dados em saúde.	Não é específico para alta segura neonatal e não contempla o conjunto de critérios clínico-assistenciais, pesos normativos e protocolos internos adotados nesta dissertação.
Miletic e Sariyar (2026)	Dados sintéticos longitudinais e temporais em saúde.	Revisão sistemática de métodos de geração sintética para dados longitudinais e séries temporais em saúde.	Discute desafios de utilidade, realismo clínico e avaliação em estruturas de dados mais complexas que tabelas transversais simples.	O escopo desta dissertação é tabular e transversal; a referência delimita o que não foi abordado e reforça a necessidade de validações futuras para dimensões temporais.

Continuação da Tabela 6

Referência	**Foco principal**	**Estratégia metodológica**	**Validação e dados**	**Lacuna em relação à proposta**
Flores et al. (2023)	Sistemas de apoio à decisão clínica baseados em Redes Bayesianas.	Framework para construção de modelos bayesianos em saúde, com ênfase em interpretabilidade e participação de especialistas.	Valoriza a incorporação de conhecimento de domínio e a transparência da estrutura probabilística.	Contribui para a justificativa do formalismo bayesiano, mas não tem como objetivo gerar dados sintéticos neonatais nem validar bases sintéticas em cenário de *cold start*.
Bernardino et al. (2024)	IA aplicada à predição de sepse neonatal.	Revisão/estudo sobre modelos de IA e Aprendizado de Máquina aplicados à identificação de sepse neonatal.	Mostra a presença crescente de abordagens *data-driven* em neonatologia e o foco em desfechos críticos.	Não aborda alta segura nem geração sintética; serve como contraste entre IA preditiva neonatal e a proposta *knowledge-driven* desta dissertação.
Lucchese et al. (2024)	Aplicativo m-Health voltado a profissionais e familiares.	Desenvolvimento tecnológico de aplicação para apoio informacional e cuidado neonatal.	Evidencia relevância de tecnologias digitais na transição de cuidados e orientação familiar.	Não gera dados sintéticos nem modela dependências probabilísticas; contribui para contextualizar a dimensão tecnológica da alta neonatal.
Neves, Junior e Franco (2026)	Uso de dados sintéticos em segmentação médica.	Avalia o impacto de dados sintéticos em modelos de segmentação de pólipos em colonoscopia.	Mostra ganhos de desempenho com suplementação sintética em contexto médico de escassez de dados anotados.	Trata imagens médicas e aprendizagem profunda, não dados tabulares neonatais; sua contribuição é contextual e periférica.

Continuação da Tabela 6

Referência	**Foco principal**	**Estratégia metodológica**	**Validação e dados**	**Lacuna em relação à proposta**
Santos, Silva e Silva (2026)	Geração de dados totalmente sintéticos para alta segura neonatal.	Rede Bayesiana *knowledge-driven*, parametrizada por literatura, diretrizes e curadoria de domínio, sem uso de prontuários reais no treinamento do gerador.	Validação interna por protocolos complementares, incluindo fidelidade estatística, inferência condicional, TSTS, explicabilidade, sensibilidade, casos-limite, fidelidade topológica e *edit checks*.	Não substitui validação clínica externa ou TSTR futuro; sua contribuição é metodológica, auditável e voltada ao estágio inicial de desenvolvimento em ausência de dados reais.

4.7 Lacunas Identificadas

A análise da literatura permite identificar lacunas que justificam a proposta desta dissertação.

1. **Predomínio de modelos preditivos dependentes de dados reais.** A literatura em IA neonatal demonstra avanços relevantes, mas os modelos de melhor desempenho geralmente dependem de bases reais extensas e rotuladas Kwok et al. (2022), Batista et al. (2021). Essa dependência limita sua adoção em cenários institucionais com escassez de dados ou restrições de acesso.

2. **Foco limitado na alta segura neonatal como transição multidimensional.** Muitos estudos concentram-se em mortalidade, sepse ou morbidades específicas, enquanto a alta segura envolve a integração de critérios biofisiológicos, preventivos, familiares e de seguimento Araujo et al. (2023), Silva et al. (2024a). Essa diferença reduz a transferibilidade direta de modelos preditivos tradicionais para o problema da desospitalização segura.

3. **Dependência de bases reais nos geradores sintéticos data-driven.** Métodos generativos orientados a dados podem produzir bases sintéticas úteis, mas usualmente necessitam de registros reais para treinamento Goncalves et al. (2020), Hernandez et al. (2022), Murtaza et al. (2023). Assim, não resolvem integralmente o *cold start*.

4. **Riscos de privacidade, memorização e reidentificação.** A literatura mostra que dados sintéticos não são automaticamente livres de risco, especialmente quando derivados de

bases reais e quando há possibilidade de proximidade excessiva entre registros sintéticos e originais Tucker et al. (2020), Yale et al. (2020), Giuffrè e Shung (2023), Murtaza et al. (2023).

5. **Plausibilidade clínica insuficientemente auditada.** A preservação de distribuições estatísticas não garante que cada registro sintético seja clinicamente plausível. Em saúde, é necessário auditar combinações individuais e identificar violações de regras de domínio Goncalves et al. (2020), Giuffrè e Shung (2023).

6. **Escassez de abordagens knowledge-driven para geração sintética neonatal.** Embora Redes Bayesianas sejam adequadas à representação de conhecimento clínico, ainda há espaço para modelos que combinem alta segura neonatal, geração totalmente sintética, ausência de prontuários reais, curadoria clínica e validação multidimensional Kaur et al. (2021), Flores et al. (2023), Santos, Silva e Silva (2026).

4.8 Posicionamento da Proposta

Diante dessas lacunas, a proposta desta dissertação ocupa um espaço específico na literatura. Ela não busca competir com modelos preditivos treinados em grandes bases reais, nem substituir validações externas futuras. Seu objetivo é oferecer uma metodologia inicial para cenários nos quais dados reais ainda não estão disponíveis ou não podem ser utilizados, mas há conhecimento clínico suficiente para estruturar uma representação probabilística auditável Goncalves et al. (2020), Kaur et al. (2021), Flores et al. (2023), Santos, Silva e Silva (2026).

A contribuição central consiste em combinar: (i) o domínio da alta segura neonatal; (ii) geração de dados totalmente sintéticos; (iii) modelagem *knowledge-driven*; (iv) Redes Bayesianas interpretáveis; (v) ausência de prontuários reais no processo de construção do gerador; e (vi) protocolos internos de validação estatística, topológica, preditiva, explicativa e clínica Araujo et al. (2023), Silva et al. (2024a), Goncalves et al. (2020), Emam et al. (2022), Hernandez et al. (2025), Kaur et al. (2021), Santos, Silva e Silva (2026).

Esse posicionamento também define os limites da proposta. A metodologia preserva propriedades probabilísticas e topológicas do modelo construído, mas não demonstra validade assistencial direta. A ausência de TSTR e de comparação com pacientes reais deve ser entendida como delimitação metodológica, não como deficiência ocultada. Em vez disso, a dissertação assume essa condição como parte do problema de pesquisa e propõe uma forma auditável de avançar no contexto de *cold start* Goncalves et al. (2020), Nisevic, Milojevic e Spajic (2025), Santos, Silva e Silva (2026).

Assim, o capítulo evidencia que a literatura cobre partes relevantes do problema, mas ainda há espaço para uma abordagem integrada, orientada por conhecimento, voltada à alta segura neonatal e capaz de gerar dados sintéticos auditáveis sem depender de bases reais iniciais

Kwok et al. (2022), Murtaza et al. (2023), Kaur et al. (2021), Silva et al. (2024a), Santos, Silva e Silva (2026).

5

Resultados e Discussões

Este capítulo apresenta os resultados obtidos nas execuções experimentais dos modelos Core11 e Core18. Como definido na metodologia, a dissertação não utilizou uma base real de pacientes para treinamento, calibração ou comparação externa. Portanto, os resultados devem ser interpretados no contexto de uma validação interna de dados sintéticos totalmente gerados por uma Rede Bayesiana *knowledge-driven*, em regime *Train on Synthetic, Test on Synthetic* (TSTS), sem aplicação de *Train on Synthetic, Test on Real* (TSTR) Rankin et al. (2020), Hernandez et al. (2025), Boni, Junior e Costa (2025).

Essa delimitação é central para a leitura dos achados. O objetivo dos experimentos não foi demonstrar validade clínica assistencial, nem comprovar capacidade de generalização para prontuários reais. O objetivo foi avaliar se o gerador sintético preserva as propriedades probabilísticas, topológicas, explicativas e clínicas previstas em sua própria modelagem, além de identificar limites de plausibilidade individual. Nesse sentido, resultados positivos e críticos são ambos relevantes: os primeiros demonstram aderência ao modelo proposto; os segundos revelam pontos de tensão que orientam refinamentos futuros.

5.1 Organização dos Resultados

Os resultados foram organizados segundo o conjunto de protocolos internos de validação descritos na metodologia. O protocolo S1 avaliou fidelidade estatística; o S2, inferência condicional; o S3, utilidade preditiva interna em regime TSTS; o S3SHAP, explicabilidade e alinhamento entre importância preditiva e pesos normativos; o S4, validação do limiar por curva ROC sintética; o S5, sensibilidade dos limiares; o S6, casos-limite compensatórios; o S7, fidelidade topológica multivariada; e o protocolo EC, aplicado ao Core18, auditou plausibilidade clínica individual por *edit checks*.

Foram consideradas duas execuções oficiais, ambas com $n = 10000$ registros sintéticos

e semente global igual a 42. A execução oficial do Core11 foi `exec_20260706_135341`; a execução oficial do Core18 foi `exec_20260708_141901`, já incorporando a EC-01 e a correção de timestamp único para os artefatos experimentais.

Tabela 7 – Execuções oficiais analisadas

Modelo	Execução	n	Timestamp
Core11	`exec_20260706_135341`	10000	`20260706_1353`
Core18	`exec_20260708_141901`	10000	`20260708_1418`

Fonte: Produção dos autores, 2026

5.2 Resultados do Core11

O Core11 funcionou como prova inicial da arquitetura. Ele incluiu 11 variáveis clínicas: Idade Gestacional, Peso, Apgar, Amamentação, Oxigenação, Respiração, Frequência Cardíaca, Temperatura, Icterícia, Triagens e Vacina. A execução oficial gerou 10000 registros sintéticos e permitiu avaliar a capacidade inicial do pipeline de representar distribuições, dependências condicionais, escore normativo e decisão de alta.

5.2.1 Distribuição das Decisões no Core11

A distribuição das categorias de decisão de alta no Core11 é apresentada na Tabela 8. Observa-se predominância da classe Alta com Recomendação, seguida por Alta Segura e Alta Contraindicada.

Tabela 8 – Distribuição das decisões de alta no Core11

Decisão	n	%
Alta Segura	1706	17,06
Alta com Recomendação	7613	76,13
Alta Contraindicada	681	6,81

Fonte: Produção dos autores, 2026

Esse comportamento é coerente com o papel do Core11 como modelo inicial, com menor número de dimensões clínicas. Como o número de variáveis avaliadas era menor, havia menos condições simultâneas a serem satisfeitas para que o registro sintético atingisse a classificação Alta Segura.

5.2.2 Protocolos de Validação no Core11

A Tabela 9 sintetiza os principais resultados de validação do Core11. Os protocolos S1 e S2 foram integralmente aprovados, indicando aderência das distribuições e das inferências

condicionais às CPTs especificadas. O S3 apresentou Kappa médio de 0,9445, interpretado como concordância quase perfeita no regime TSTS. O S7 também foi aprovado, com 11/11 variáveis dentro do limiar de Hellinger e PCD-MAD de 0,0088.

Tabela 9 – Síntese dos protocolos de validação do Core11

Protocolo	**Resultado**	**Leitura**
S1	7/7	Fidelidade estatística preservada.
S2	7/7	Inferências condicionais preservadas.
S3	Kappa = 0,9445	Utilidade preditiva interna quase perfeita.
S3SHAP	$\rho = -0,0818$	Concordância explicativa não aprovada.
S4	Limiar ótimo = 168; normativo = 112	Divergência entre limiar ótimo e normativo.
S5	Instável	Sensibilidade relevante aos limiares.
S6	0 paradoxais	Nenhum caso compensatório paradoxal detectado.
S7	Hellinger 11/11; PCD-MAD = 0,0088	Fidelidade topológica preservada.

Fonte: Produção dos autores, 2026

Os resultados do Core11 demonstram que a arquitetura inicial foi capaz de gerar dados sintéticos estatística e topologicamente coerentes com as premissas implementadas. Entretanto, os achados de S3SHAP, S4 e S5 já indicavam que a concordância estatística do gerador não elimina tensões entre estrutura normativa, importância preditiva e estabilidade dos limiares.

5.3 Resultados do Core18

O Core18 representa a versão principal desta dissertação. Em relação ao Core11, foram incorporadas sete variáveis: Eliminações, Exame Físico, Sinais de Alerta, Pressão Arterial, Coto Umbilical, Pele e Sono. Essa expansão aumentou a cobertura biofisiológica do modelo, ampliou a complexidade topológica e permitiu aplicar o protocolo EC de auditoria clínica pós-geração.

5.3.1 Distribuição das Decisões no Core18

A Tabela 10 apresenta a distribuição das decisões de alta na execução oficial do Core18. Em comparação com o Core11, houve redução proporcional de Alta Segura e aumento de Alta com Recomendação.

Tabela 10 – Distribuição das decisões de alta no Core18

Decisão	**n**	**%**
Alta Segura	706	7,06
Alta com Recomendação	8783	87,83
Alta Contraindicada	511	5,11

Fonte: Produção dos autores, 2026

A Figura 5 apresenta a distribuição percentual das decisões de alta nas execuções oficiais Core11 e Core18.

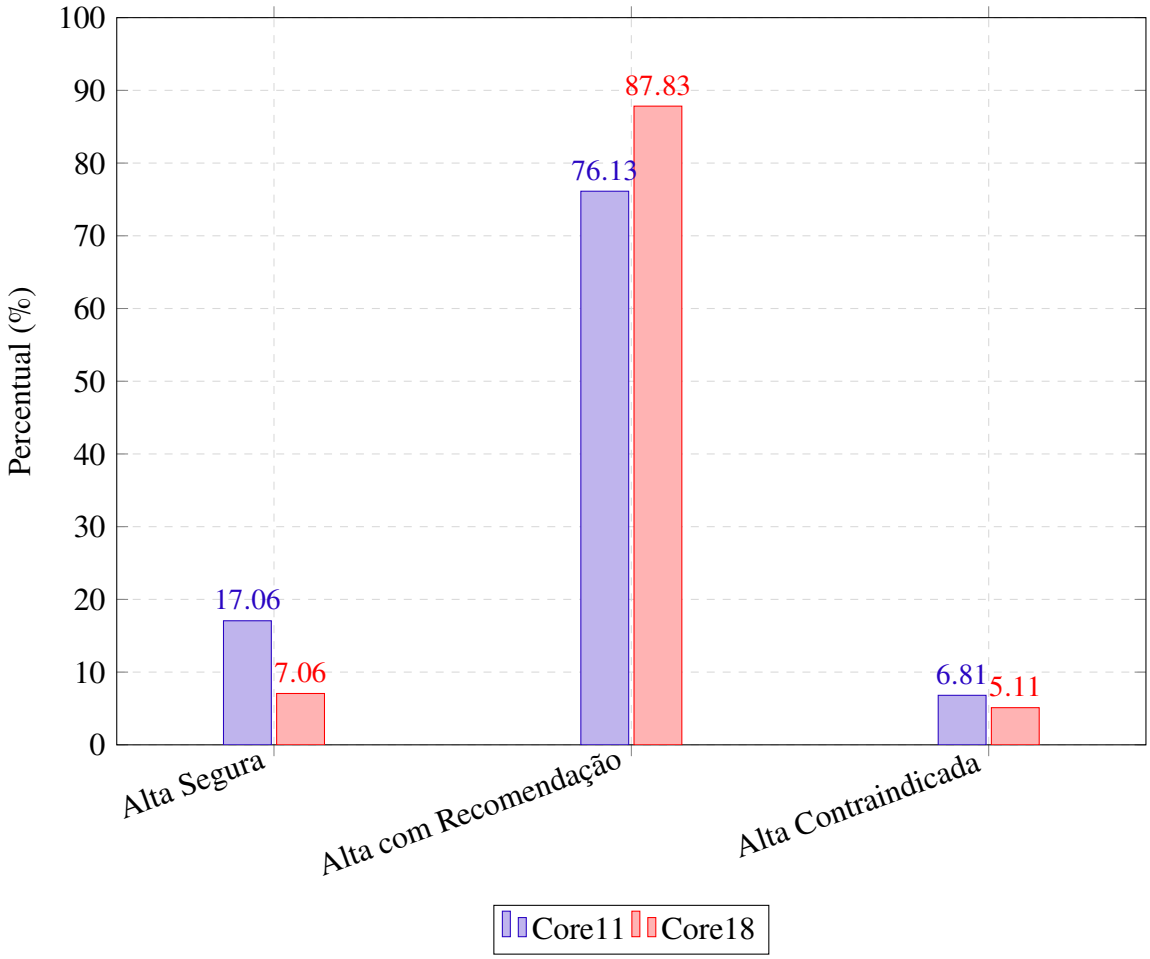


Figura 5 – Distribuição percentual das decisões de alta nas execuções oficiais Core11 e Core18, reconstruída a partir dos resultados experimentais exportados pelo algoritmo.

Fonte: Produção dos autores, 2026

A comparação evidencia uma mudança relevante no comportamento da classificação após a expansão do modelo. No Core11, a categoria Alta Segura representou 17,06% dos registros, enquanto no Core18 essa proporção caiu para 7,06%. Em sentido oposto, a categoria Alta com Recomendação aumentou de 76,13% para 87,83%. A categoria Alta Contraindicada apresentou pequena redução, de 6,81% para 5,11%.

Esse deslocamento sugere que a expansão para 18 variáveis tornou a classificação mais conservadora para a concessão de Alta Segura. A interpretação mais adequada não é que o Core18 tenha se tornado apenas mais severo, mas que passou a capturar um número maior de situações intermediárias de prontidão clínica. Como o modelo expandido incorpora novas dimensões biofisiológicas, como eliminações, exame físico, sinais de alerta, pressão arterial, coto umbilical, integridade da pele e sono, torna-se mais difícil que um registro sintético satisfaça simultaneamente todas as condições necessárias para ser classificado como Alta Segura.

5.3.2 Fidelidade Estatística e Inferência Condicional

No Core18, o protocolo S1 aprovou 7/7 testes, indicando preservação das distribuições e dependências fundamentais avaliadas. O protocolo S2 aprovou 14/14 casos, incorporando os cenários condicionais adicionais associados às variáveis expandidas. Esses resultados indicam que a expansão do modelo não comprometeu a aderência computacional às CPTs e aos zeros estruturais especificados.

Tabela 11 – Resultados de S1 e S2 no Core18

Protocolo	**Resultado**	**Interpretação**
S1	7/7	Fidelidade estatística preservada.
S2	14/14	Inferências condicionais preservadas.

Fonte: Produção dos autores, 2026

Esses achados são relevantes porque indicam que a inclusão de novos nós e CPTs não introduziu, na execução oficial, ruptura estatística evidente nos testes internos de aderência. A rede expandida continuou respeitando as probabilidades e relações condicionais que foram explicitamente parametrizadas.

5.3.3 Utilidade Preditiva Interna e Explicabilidade

O protocolo S3 apresentou Kappa médio de 0,9209, com desvio-padrão de 0,0079, mantendo a interpretação de concordância quase perfeita no regime TSTS. Esse resultado indica que as variáveis sintéticas geradas carregam sinal analítico suficiente para que um classificador externo aprenda a decisão normativa derivada do escore.

Entretanto, o S3 não deve ser interpretado como validação clínica externa. Como o treinamento e o teste ocorrem no próprio universo sintético, o resultado demonstra coerência interna da base e aprendibilidade do rótulo normativo, mas não capacidade de generalização para pacientes reais.

O S3SHAP apresentou correlação de Spearman negativa entre o ranking de importância explicativa e os pesos normativos ($\rho = -0,1909$; $p = 0,4479$), sendo classificado como não aprovado. A coerência biofisiológica registrada foi de 7/14. Esse achado indica que o classificador

externo aprendeu padrões dominantes do universo sintético que não coincidiram integralmente com a hierarquia normativa esperada.

A Figura 6 apresenta o ranking de importância das variáveis estimado pelo protocolo S3SHAP no Core18. O resultado permite visualizar que a importância preditiva aprendida no universo sintético não reproduziu integralmente a hierarquia normativa definida na modelagem.

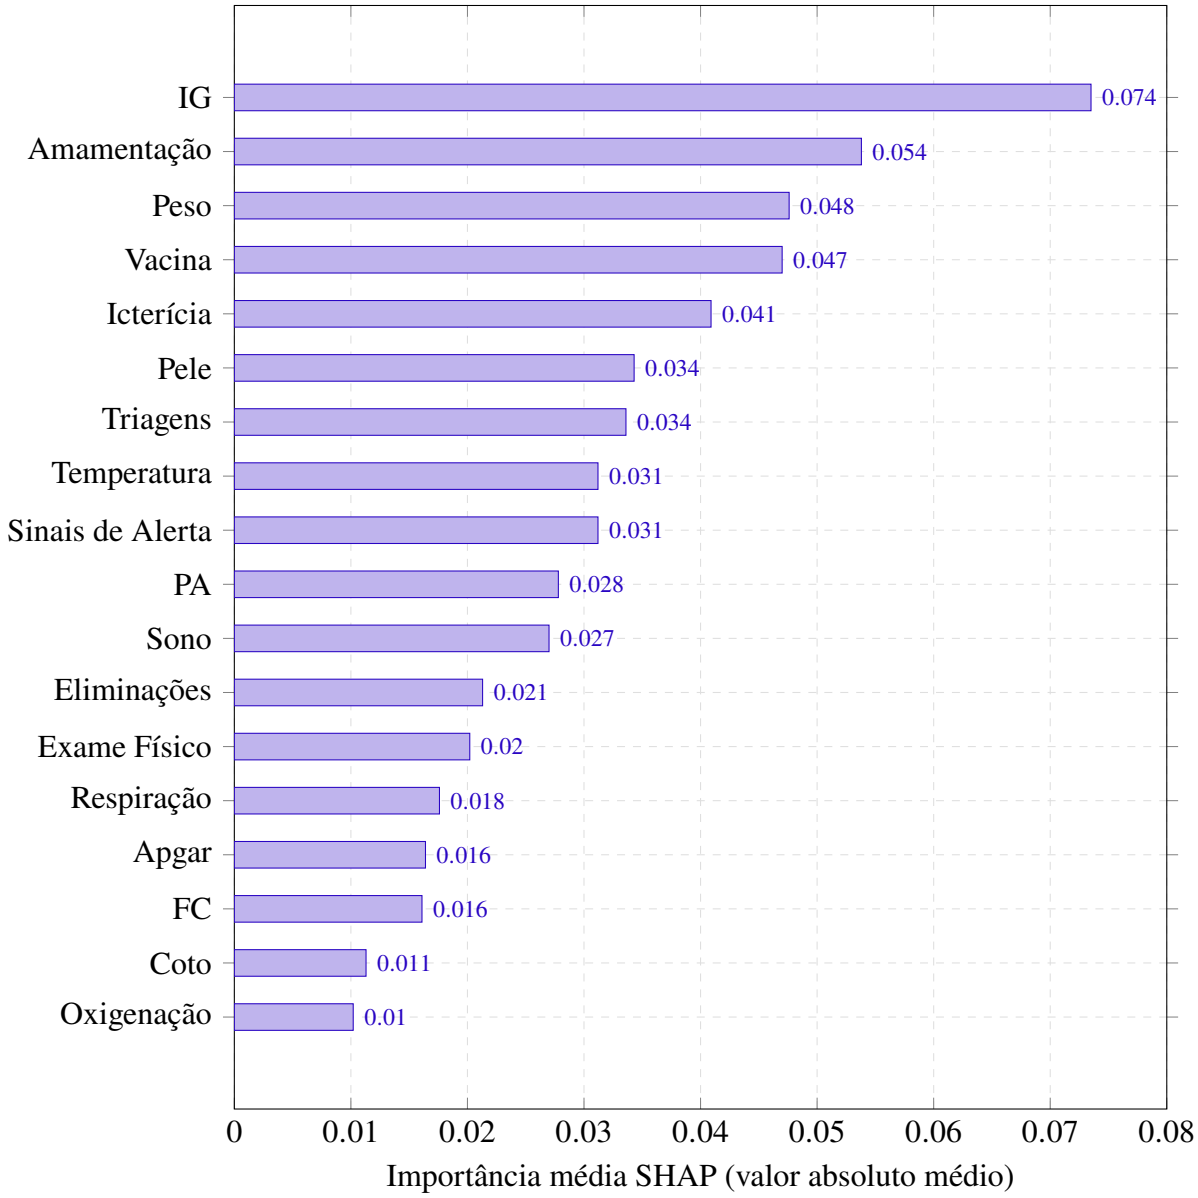


Figura 6 – Ranking de importância das variáveis no protocolo S3SHAP para o Core18.

Fonte: Produção dos autores, 2026.

A visualização do ranking reforça a interpretação de que o classificador treinado no universo sintético atribuiu maior relevância a variáveis estruturais e de alta frequência discriminativa, como IG, Amamentação, Peso e Vacina. Esse padrão não coincide integralmente

com a hierarquia normativa esperada, na qual variáveis biofisiológicas críticas, como Oxigenação, Respiração e Frequência Cardíaca, possuem maior peso clínico. Assim, o resultado do S3SHAP não deve ser lido como falha isolada do classificador, mas como evidência de que importância preditiva, frequência de ocorrência e peso clínico-normativo são dimensões distintas no modelo sintético.

A Tabela 12 sintetiza os resultados quantitativos dos protocolos S3 e S3SHAP no Core18.

Tabela 12 – Resultados de S3 e S3SHAP no Core18

Protocolo	**Resultado**	**Interpretação**
S3	Kappa = 0,9209	Utilidade preditiva interna quase perfeita.
S3SHAP	$\rho = -0,1909$	Ranking explicativo não alinhado aos pesos normativos.
S3SHAP	7/14	Coerência biofisiológica parcial.

Fonte: Produção dos autores, 2026

A combinação entre S3 e S3SHAP é metodologicamente importante. O alto Kappa mostra que o dataset tem estrutura preditiva interna; o resultado crítico do SHAP mostra que utilidade preditiva não equivale, necessariamente, a alinhamento explicativo com os pesos clínicos normativos. Essa distinção reforça a necessidade de avaliação multidimensional em dados sintéticos de saúde Emam et al. (2022), Hernandez et al. (2025). A leitura do Kappa como concordância quase perfeita segue a referência clássica para interpretação de concordância categórica Landis e Koch (1977).

5.3.4 Validação dos Limiares e Casos-Limite

Os protocolos S4, S5 e S6 avaliaram o comportamento do sistema de escore e dos limiares normativos. O S4 identificou AUC de 1,0000, limiar ótimo de 294 pontos e limiar normativo de 196 pontos, com diferença de 98 pontos. Esse resultado indica divergência entre o ponto matematicamente ótimo no universo sintético e o limiar normativo definido para o Core18.

A Figura 7 sintetiza o principal achado do protocolo S4: a divergência entre o limiar normativo de 196 pontos e o limiar ótimo de Youden, estimado em 294 pontos no universo sintético.

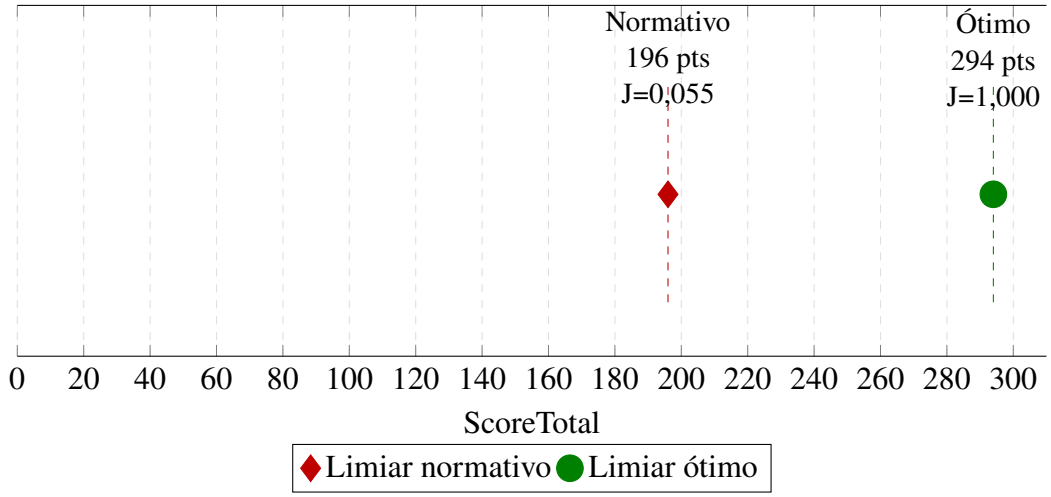


Figura 7 – Comparação entre limiar normativo e limiar ótimo de Youden no protocolo S4 para o Core18.

Fonte: Produção dos autores, 2026.

A comparação visual entre os dois limiares evidencia que o ponto ótimo estimado no universo sintético se encontra no valor máximo do escore, enquanto o limiar normativo permanece em 196 pontos. Essa divergência não invalida o limiar normativo, pois este deriva de uma regra de decisão clínica previamente definida, e não de otimização estatística sobre a base sintética. No entanto, o resultado indica que, no universo gerado, o ponto matematicamente mais discriminativo para separar Alta Segura das demais categorias foi mais restritivo do que o limiar originalmente estabelecido.

O S5 indicou instabilidade na análise de sensibilidade dos limiares, com maior variação observada em 252 pontos. Já o S6 não identificou casos paradoxais compensatórios, registrando 0 casos paradoxais entre os perfis analisados na zona de borda.

Tabela 13 – Resultados dos protocolos de limiar no Core18

Protocolo	**Resultado**	**Interpretação**
S4	Ótimo = 294; normativo = 196	Divergência de 98 pontos.
S5	Instável	Decisão sensível a variações de limiar.
S6	0 paradoxais	Ausência de casos compensatórios paradoxais.

Fonte: Produção dos autores, 2026

Esses achados sugerem uma tensão entre a lógica normativa do instrumento e o comportamento matemático observado no universo sintético. O resultado de S4 não invalida o modelo, mas indica que o limiar normativo não coincide com o ponto de separação ótimo encontrado pela curva ROC sintética. O resultado de S5 reforça que a escolha dos limiares influencia de forma relevante a distribuição das classes. Por outro lado, o S6 contribui positivamente ao indicar que,

na execução oficial, não foram identificados perfis paradoxais que alcançassem aprovação por compensação inadequada entre dimensões.

5.3.5 Fidelidade Topológica Multivariada

O protocolo S7 avaliou se a expansão para 18 variáveis preservou a estrutura probabilística global do modelo. A Distância de Hellinger aprovou 18/18 variáveis, e a Diferença de Correlação Pareada apresentou PCD-MAD de 0,0097, abaixo do limiar de 0,05. O maior desvio observado ocorreu no par Apgar × Oxigenação, com PCD-MAX de 0,0396.

Tabela 14 – Resultados de S7 no Core18

Métrica	**Resultado**	**Interpretação**
Hellinger	18/18	Marginais preservadas.
PCD-MAD	0,0097	Dependências globais preservadas.
PCD-MAX	0,0396	Maior desvio em Apgar × Oxigenação.

Fonte: Produção dos autores, 2026

A Figura 8 detalha os valores da Distância de Hellinger por variável no Core18, complementando a síntese apresentada na Tabela 14. Todas as 18 variáveis permaneceram dentro do critério de aprovação, reforçando a preservação das distribuições marginais no modelo expandido.

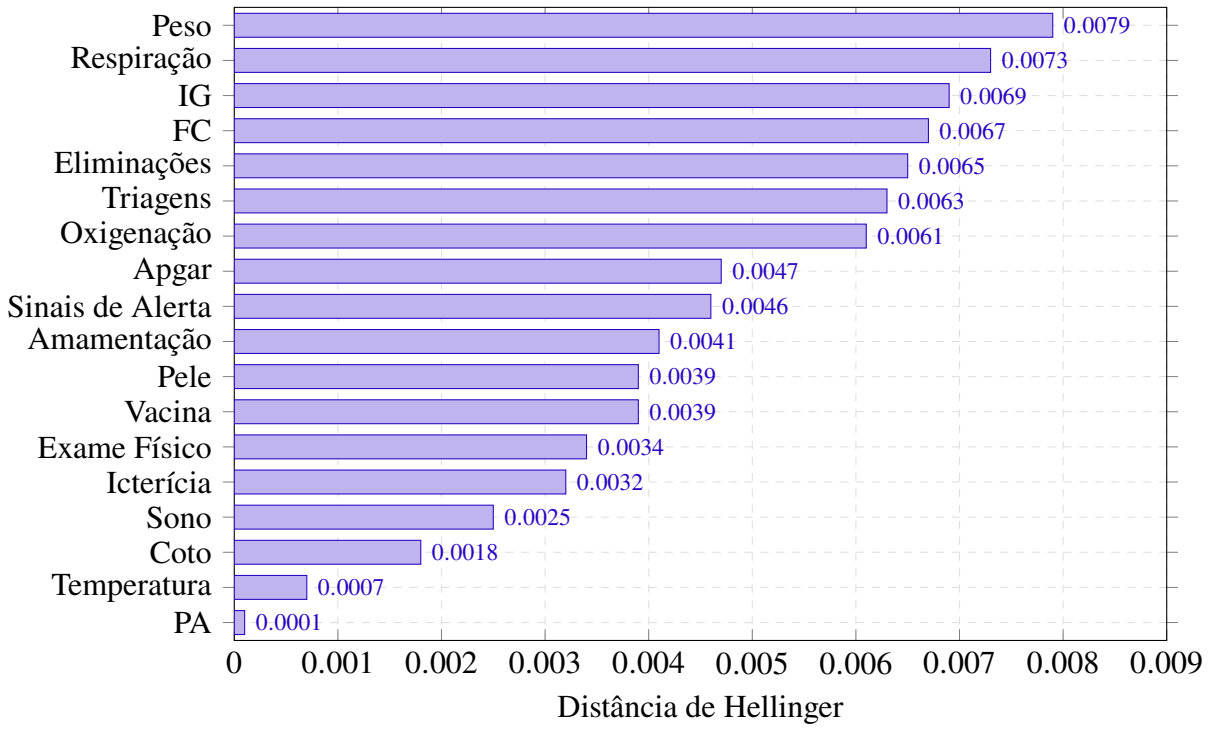


Figura 8 – Distância de Hellinger por variável no protocolo S7 para o Core18.

Fonte: Produção dos autores, 2026.

O S7 é um dos resultados mais fortes do Core18, pois mostra que a expansão não comprometeu a fidelidade topológica multivariada. O gerador preservou não apenas distribuições marginais, mas também a estrutura geral de dependências definida pelas CPTs, aspecto reconhecido como central na avaliação de dados sintéticos tabulares em saúde Emam et al. (2022), Hernandez et al. (2025), Boni, Junior e Costa (2025), Chundawat et al. (2022).

5.3.6 Auditoria por Edit Checks

O protocolo EC foi aplicado ao Core18 como auditoria pós-geração. Na execução oficial, foram avaliadas 14 regras, incluindo a EC-01, que audita a combinação entre Apgar deprimido e sono adequado. O protocolo identificou 3686 linhas com ao menos uma violação, correspondendo a 36,9% dos 10000 registros sintéticos. Das 14 regras, 2 não apresentaram violações.

Tabela 15 – Síntese do protocolo EC no Core18

Indicador	**Resultado**
Total de regras EC	14
Regras sem violação	2
Linhas com ao menos uma violação	3686
Percentual de linhas com violação	36,9%
Violação EC-01	236 (2,36%)

Fonte: Produção dos autores, 2026

A Tabela 16 apresenta a distribuição das violações por regra. As maiores frequências ocorreram em EC-14, EC-13, EC-02 e EC-05, associadas, respectivamente, a hipotensão com decisão de alta, triagens encaminhadas com decisão de alta, temperatura alterada com sinais de alerta ausentes e hipoxemia com respiração normal.

Tabela 16 – Violações por edit check no Core18

Código	Regra auditada	n	%
EC-01	Apgar deprimido com sono adequado	236	2,36
EC-02	Temperatura alterada com sinais de alerta ausentes	589	5,89
EC-03	Icterícia grave com sinais de alerta ausentes	513	5,13
EC-04	Amamentação eficaz com sinais de alerta frequentes	302	3,02
EC-05	Hipoxemia com respiração normal	563	5,63
EC-06	Taquipneia com amamentação eficaz	278	2,78
EC-09	Sinais de alerta frequentes com sono adequado	473	4,73
EC-10	Coto inflamado com temperatura alterada	43	0,43
EC-11	Lesão de pele com sinais de alerta ausentes	383	3,83
EC-12	Sono insuficiente com amamentação eficaz	333	3,33
EC-13	Triagens encaminhadas com decisão de alta	705	7,05
EC-14	Hipotensão com decisão de alta	877	8,77
EC-15	Sinais de alerta frequentes com Alta Segura	0	0,00
EC-16	Exame físico cirúrgico com Alta Segura	0	0,00

Fonte: Produção dos autores, 2026

A Figura 9 representa graficamente a distribuição das violações por edit check no Core18. Observa-se maior concentração de inconsistências nas regras EC-14, EC-13, EC-02 e EC-05, reforçando que a auditoria clínica linha a linha revela fragilidades não capturadas apenas por métricas agregadas.

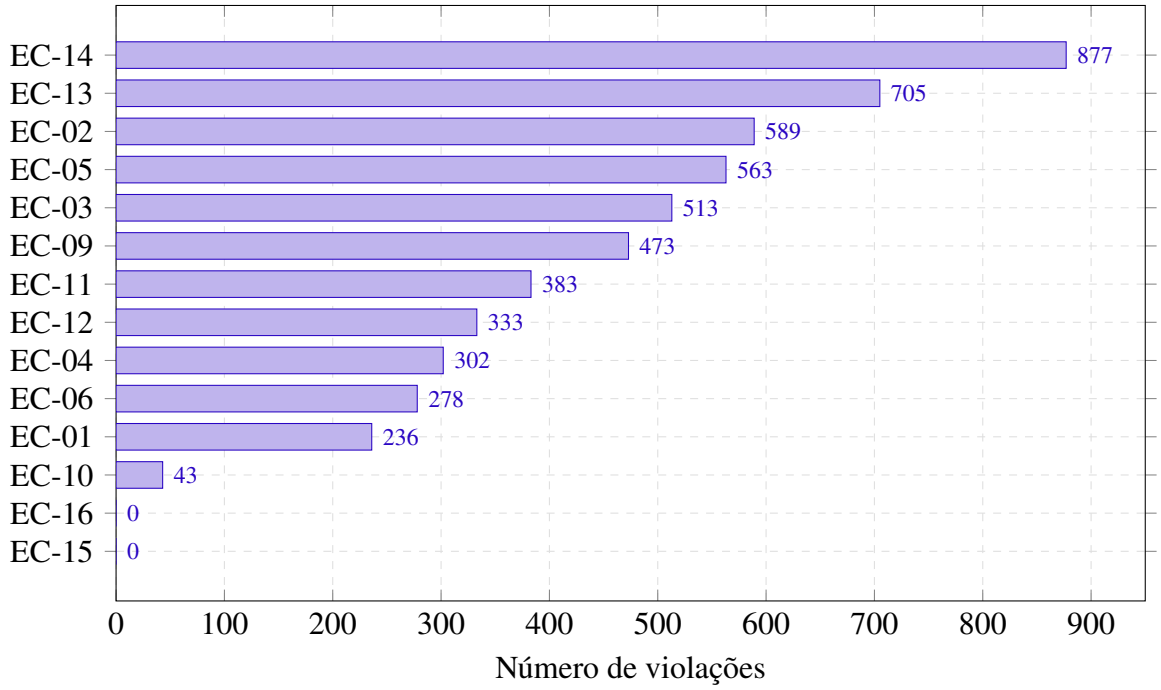


Figura 9 – Distribuição das violações por edit check na execução oficial do Core18.

Fonte: Produção dos autores, 2026.

O resultado do EC é um dos achados mais relevantes da dissertação. Ele mostra que, embora a Rede Bayesiana preserve propriedades estatísticas e topológicas globais, parte dos registros sintéticos ainda contém combinações clinicamente discutíveis linha a linha. Essa constatação não deve ser interpretada como falha simples do gerador, mas como evidência de que coerência agregada e plausibilidade clínica individual são dimensões distintas. Esse achado dialoga com a literatura que recomenda auditoria em múltiplas escalas, incluindo avaliação global, avaliação por tarefa e inspeção de amostras individuais quando o uso pretendido envolve domínio sensível Alaa et al. (2022), Emam et al. (2022), Hernandez et al. (2025).

No desenho atual, os edit checks não filtram registros, não alteram CPTs e não executam reamostragem condicionada. Eles funcionam como mecanismo de auditoria pós-geração. Assim, as violações observadas revelam limites do Core18 e indicam caminhos de aprimoramento, especialmente a avaliação futura de filtros clínicos, rejeição automática de amostras, reamostragem condicionada ou incorporação de restrições adicionais diretamente nas CPTs. A EC-01, com 236 violações, é particularmente útil para mostrar que uma regra clinicamente clara pode ser usada como auditoria sem mascarar o comportamento natural do gerador.

5.4 Comparação entre Core11 e Core18

A comparação entre Core11 e Core18 permite avaliar se a expansão do modelo preservou a arquitetura metodológica. A Tabela 17 sintetiza os principais resultados.

Tabela 17 – Comparação dos principais resultados entre Core11 e Core18

Indicador	**Core11**	**Core18**
Variáveis clínicas	11	18
n	10000	10000
S1	7/7	7/7
S2	7/7	14/14
Kappa S3	0,9445	0,9209
S3SHAP	$\rho = -0,0818$	$\rho = -0,1909$
S4	$\Delta = 56$ pontos	$\Delta = 98$ pontos
S5	Instável	Instável
S6	0 paradoxais	0 paradoxais
S7 Hellinger	11/11	18/18
S7 PCD-MAD	0,0088	0,0097
EC	Não aplicado	36,9% de linhas violadas

Fonte: Produção dos autores, 2026

De modo geral, a expansão para Core18 preservou os resultados fortes observados no Core11 em fidelidade estatística, inferência condicional, utilidade preditiva interna e fidelidade topológica. A pequena redução do Kappa em S3 não compromete a interpretação geral, pois ambos os modelos permaneceram na faixa de concordância quase perfeita.

Por outro lado, o Core18 tornou mais visíveis os limites do gerador. O aumento da dimensionalidade ampliou a possibilidade de combinações individuais clinicamente discutíveis, evidenciadas pelo protocolo EC. Esse resultado reforça a pertinência da estratégia incremental adotada: ao expandir o modelo, tornou-se possível observar não apenas ganhos de cobertura clínica, mas também novos pontos de vulnerabilidade.

5.5 Discussão Integrada dos Achados

Os resultados sustentam três interpretações principais. A primeira é que a abordagem knowledge-driven por Rede Bayesiana foi capaz de gerar dados sintéticos com fidelidade às premissas probabilísticas definidas. Isso é evidenciado pelos resultados de S1, S2 e S7, especialmente no Core18, em que 18/18 variáveis foram aprovadas pela Distância de Hellinger e o PCD-MAD permaneceu baixo. Esse resultado aproxima-se da proposta de recomendações recentes de avaliação multivariada de dados sintéticos, mas com uma diferença central: aqui, a referência de validação interna é o próprio modelo normativo, e não uma coorte real de origem Emam et al. (2022), Hernandez et al. (2025), Boni, Junior e Costa (2025).

A segunda interpretação é que a base sintética possui sinal analítico interno. O S3 demonstrou que a decisão normativa de alta é aprendível por um classificador externo, tanto no Core11 quanto no Core18. Entretanto, como a avaliação foi conduzida em regime TSTS, esse achado deve ser limitado à coerência interna do universo sintético.

A terceira interpretação é que a plausibilidade clínica individual exige auditoria própria. Os resultados de EC mostram que uma base pode ser estatística e topologicamente coerente e, ainda assim, conter combinações individuais pouco plausíveis. Essa distinção é uma das contribuições centrais da dissertação, pois evita a equivalência indevida entre fidelidade probabilística agregada e realismo clínico linha a linha.

Os achados críticos de S3SHAP, S4, S5 e EC não reduzem a contribuição do trabalho; ao contrário, tornam a proposta metodologicamente mais robusta. Eles demonstram que o pipeline não foi construído apenas para confirmar a hipótese de funcionamento do gerador, mas também para revelar seus limites. Essa postura é particularmente importante em saúde, onde resultados sintéticos não devem ser apresentados como automaticamente plausíveis ou clinicamente seguros Giuffrè e Shung (2023), Kaabachi et al. (2025), Nisevic, Milojevic e Spajic (2025).

5.6 Ameaças à Validade

Embora os resultados apresentados indiquem coerência estatística, topológica e inferencial do gerador sintético, é necessário reconhecer ameaças à validação do estudo. Essas ameaças não invalidam os achados, mas delimitam seu escopo e orientam a forma correta de interpretá-los, especialmente porque a avaliação de dados sintéticos em saúde exige distinção entre

fidelidade, utilidade, privacidade, plausibilidade clínica e generalização externa Emam et al. (2022), Hernandez et al. (2025), Boni, Junior e Costa (2025). Nesta dissertação, a identificação dessas ameaças foi acompanhada por estratégias explícitas de mitigação, de modo que a avaliação não se restringisse à apresentação de limitações, mas também evidenciasse os mecanismos adotados para reduzir seus efeitos sobre os resultados.

5.6.1 Validade Interna

A principal ameaça à validade interna decorre do fato de a Rede Bayesiana ter sido construída por uma abordagem *knowledge-driven*, sem aprendizado estrutural ou paramétrico a partir de uma coorte real. Nesse cenário, erros de especificação na topologia, nas CPTs, nos pesos normativos ou nas regras de decisão poderiam comprometer a coerência do universo sintético gerado, uma vez que modelos sintéticos dependem diretamente das premissas e mecanismos utilizados em sua geração Rankin et al. (2020), Hernandez et al. (2025). Para mitigar esse risco, a modelagem foi conduzida de forma rastreável, com documentação das variáveis, relações causais, CPTs e justificativas normativas apresentadas nos capítulos anteriores e nos artefatos complementares da dissertação.

Além disso, foram adotados protocolos de validação interna complementares. O S1 verificou a aderência das distribuições marginais, o S2 avaliou inferências condicionais esperadas, o S3 examinou se a decisão normativa era aprendível dentro do próprio universo sintético e o S7 testou a preservação de propriedades multivariadas e topológicas. Essa combinação de testes segue a recomendação de avaliar dados sintéticos por múltiplas dimensões, evitando depender de uma única métrica de fidelidade ou utilidade Emam et al. (2022), Hernandez et al. (2025). A aprovação desses protocolos no Core18, especialmente com 18/18 variáveis dentro do limiar de Hellinger e PCD-MAD de 0,0097, constitui evidência de que o gerador preservou, em nível agregado, as propriedades especificadas na modelagem.

Outra ameaça interna está relacionada à possibilidade de que métricas agregadas ocultem combinações individuais clinicamente frágeis. Essa preocupação é particularmente relevante em saúde, pois dados sintéticos podem apresentar boa fidelidade estatística e, ainda assim, exigir validações específicas de plausibilidade e uso pretendido Giuffrè e Shung (2023), Kaabachi et al. (2025), Nisevic, Milojevic e Spajic (2025). Essa ameaça foi diretamente evidenciada pelo protocolo EC, que identificou violações em 36,9% dos registros sintéticos do Core18. A inclusão desse protocolo atuou como estratégia de mitigação metodológica, pois impediu que a validade estatística global fosse confundida com plausibilidade clínica linha a linha. Assim, a própria detecção das violações deve ser interpretada como evidência de funcionamento do pipeline de auditoria, e não apenas como fragilidade do modelo.

5.6.2 Validade Externa

A ameaça mais relevante à validade externa é a ausência de comparação com dados reais de pacientes. Como não houve treinamento, calibração ou teste com prontuários hospitalares, os resultados não permitem afirmar validade clínica externa, desempenho assistencial prospectivo ou capacidade de generalização para diferentes maternidades, populações ou contextos institucionais. Em particular, a dissertação não executou validação em regime *Train on Synthetic, Test on Real* (TSTR), o que limita a interpretação dos achados ao regime *Train on Synthetic, Test on Synthetic* (TSTS), distinção central na literatura de avaliação de dados sintéticos Rankin et al. (2020), Hittmeir, Ekelhart e Mayer (2019), Hernandez et al. (2025).

Essa ameaça foi mitigada por delimitação explícita do escopo desde a introdução, a metodologia e a abertura deste capítulo. Os resultados foram apresentados como evidências de validação interna de um gerador totalmente sintético em cenário de *cold start*, e não como comprovação de validade assistencial direta. Essa decisão reduz o risco de superinterpretação dos achados e preserva a coerência entre problema, método e conclusão, em consonância com recomendações de cautela no uso de dados sintéticos em contextos clínicos Giuffrè e Shung (2023), Hernandez et al. (2025), Nisevic, Milojevic e Spajic (2025).

Também se buscou mitigar a ameaça à generalização por meio da descrição detalhada da arquitetura, dos protocolos de validação, das execuções oficiais, dos parâmetros experimentais e dos artefatos gerados. Essa transparência permite que estudos futuros reproduzam, auditem ou adaptem o pipeline em outros contextos, inclusive com bases reais, validação por especialistas e avaliação TSTR. Dessa forma, embora a validade externa permaneça limitada, a dissertação oferece uma base metodológica auditável para sua ampliação futura.

5.6.3 Validade de Construto

A validade de construto diz respeito à correspondência entre os conceitos avaliados e as métricas utilizadas para representá-los. Uma ameaça neste estudo é assumir que fidelidade estatística, coerência topológica, utilidade preditiva interna, explicabilidade e plausibilidade clínica medem um único fenômeno de validade. Os resultados demonstram que essa equivalência seria inadequada: o Core18 apresentou bom desempenho em S1, S2, S3 e S7, mas também exibiu divergência no S3SHAP, instabilidade nos limiares em S4 e S5 e violações clínicas no EC.

Para mitigar essa ameaça, a dissertação adotou uma estratégia multidimensional de validação. Cada protocolo foi associado a uma dimensão específica do problema: fidelidade estatística, inferência condicional, utilidade preditiva interna, explicabilidade, estabilidade de limiares, análise de casos-limite, fidelidade topológica e plausibilidade clínica individual. Essa separação evita que uma métrica favorável seja utilizada como evidência suficiente para todos os aspectos da validade dos dados sintéticos, o que está alinhado a propostas recentes de avaliação por múltiplos critérios em dados tabulares sintéticos de saúde Emam et al. (2022), Hernandez et

al. (2025), Boni, Junior e Costa (2025).

Outra ameaça de construto está relacionada ao próprio conceito de alta segura neonatal, que envolve dimensões clínicas, preventivas, assistenciais e contextuais. A modelagem por variáveis discretas e CPTs necessariamente simplifica esse fenômeno. Como mitigação, a dissertação expandiu o Core11 para o Core18, incorporando novas variáveis biofisiológicas e assistenciais, e aplicou *edit checks* clínicos para avaliar combinações individuais não capturadas adequadamente apenas por distribuições agregadas. Ainda assim, o construto permanece uma aproximação operacional, e não uma representação completa da decisão clínica real.

5.6.4 Validade de Conclusão

As ameaças à validade de conclusão estão associadas ao risco de extrapolar os resultados para além do que os dados e protocolos permitem sustentar. A elevada concordância no S3, por exemplo, indica que a decisão normativa é aprendível dentro do universo sintético, mas não demonstra que um classificador treinado nesses dados teria desempenho semelhante em pacientes reais, pois a utilidade de dados sintéticos depende da tarefa, do domínio e do regime de validação adotado Hittmeir, Ekelhart e Mayer (2019), Rankin et al. (2020), Hernandez et al. (2025). Da mesma forma, a aprovação em S1, S2 e S7 indica aderência ao modelo gerador, mas não comprova realismo clínico pleno.

Essa ameaça foi mitigada pela interpretação cautelosa dos resultados ao longo do capítulo. Os achados foram discutidos como evidências de coerência interna, preservação topológica e funcionamento do pipeline de validação, evitando-se conclusões de eficácia clínica, segurança assistencial ou generalização externa. Os resultados negativos e críticos também foram incorporados à discussão, especialmente a reprovação do S3SHAP, a divergência entre limiar normativo e limiar ótimo no S4, a instabilidade do S5 e as violações do EC.

Por fim, a execução com 10000 registros sintéticos em cada modelo contribuiu para reduzir oscilações amostrais nos protocolos aplicados, mas não elimina as limitações inerentes ao desenho experimental. O tamanho da amostra sintética fortalece a estabilidade das estimativas internas, enquanto a ausência de dados reais mantém a conclusão restrita ao universo modelado. Assim, a principal conclusão validamente sustentada é que a abordagem proposta produz dados sintéticos internamente coerentes e auditáveis, mas ainda dependentes de refinamento clínico, calibração externa e validação futura com especialistas e bases reais, como também apontam discussões recentes sobre validação, governança e adoção responsável de dados sintéticos em saúde Giuffrè e Shung (2023), Hernandez et al. (2025), Kaabachi et al. (2025).

5.7 Síntese do Capítulo

Este capítulo apresentou os resultados das execuções oficiais Core11 e Core18. O Core11 confirmou a viabilidade inicial da arquitetura, enquanto o Core18 demonstrou capacidade de

expansão para maior cobertura clínica, preservando propriedades estatísticas e topológicas relevantes.

Ao mesmo tempo, a expansão para Core18 evidenciou limites importantes. A reprovação do S3SHAP, a divergência do S4, a instabilidade do S5 e as violações identificadas pelo EC indicam que a geração sintética em saúde deve ser avaliada por múltiplas dimensões. A principal conclusão dos resultados é que o modelo preserva propriedades probabilísticas e topológicas do universo definido pelas CPTs, mas a plausibilidade clínica individual plena ainda requer auditoria, refinamento e validação futura Goncalves et al. (2020), Hernandez et al. (2025).

6

Considerações Finais e Trabalhos Futuros

Esta dissertação teve como objetivo propor e avaliar uma metodologia para geração de dados sintéticos neonatais orientada por conhecimento, aplicada ao contexto de alta segura do recém-nascido. A pesquisa partiu de um problema recorrente em saúde digital: a necessidade de desenvolver, testar e auditar modelos computacionais em cenários nos quais bases reais de pacientes são indisponíveis, restritas por privacidade ou inadequadas para uso em uma etapa inicial de prova de conceito.

Para enfrentar esse problema, foi construída uma abordagem *knowledge-driven* baseada em redes bayesianas, na qual variáveis clínicas, dependências, CPTs, pesos normativos, escore de alta e regras de auditoria foram definidos a partir de conhecimento clínico, literatura, documentos normativos e curadoria metodológica. A proposta não dependeu de prontuários reais para treinar ou calibrar o gerador, preservando o caráter totalmente sintético da base produzida e dialogando com a literatura que trata dados sintéticos como alternativa metodológica em cenários de privacidade, escassez e restrição de acesso a dados clínicos Goncalves et al. (2020), Jordon et al. (2022), Hernandez et al. (2025), Boni, Junior e Costa (2025).

6.1 Retomada dos Objetivos

O objetivo geral foi atingido ao construir um pipeline computacional capaz de gerar registros sintéticos de alta neonatal e avaliá-los por protocolos internos de validação. Esse pipeline incluiu: seleção incremental de variáveis, modelagem causal por DAG, parametrização de CPTs, amostragem pela Rede Bayesiana, cálculo de escore, classificação normativa da decisão de alta, geração de artefatos experimentais e validação multidimensional.

A estratégia incremental foi importante para controlar a complexidade do problema. O Core11 funcionou como prova inicial da arquitetura, demonstrando que a Rede Bayesiana poderia gerar dados sintéticos coerentes com as premissas implementadas. O Core18, por sua

vez, representou a versão principal desta dissertação, expandindo a cobertura clínica do modelo e permitindo avaliar a robustez da metodologia diante de maior dimensionalidade e maior complexidade topológica.

6.2 Principais Contribuições

A principal contribuição desta dissertação não é apenas a geração de uma base sintética, mas a proposição de um processo auditável de modelagem, geração, validação e identificação de limites. Em um domínio sensível como a saúde neonatal, a simples produção de registros artificiais não é suficiente; é necessário demonstrar como esses registros foram gerados, quais premissas sustentam o modelo e quais mecanismos permitem avaliar sua coerência.

Uma primeira contribuição foi demonstrar a viabilidade de uma Rede Bayesiana orientada por conhecimento para geração de dados sintéticos em cenário de *cold start*. A ausência de prontuários reais, que em muitos contextos seria apenas uma limitação, foi tratada como parte do problema metodológico. A dissertação mostrou que é possível avançar na construção de artefatos computacionais iniciais mesmo sem uma base real, desde que as premissas sejam explicitadas, documentadas e auditadas.

Uma segunda contribuição foi a distinção entre fidelidade probabilística agregada e plausibilidade clínica individual. Os resultados mostraram que o Core18 preservou propriedades estatísticas e topológicas relevantes, mas ainda produziu registros com violações de *edit checks*. Essa constatação é importante porque evita a interpretação simplista de que bons resultados marginais ou multivariados garantem realismo clínico linha a linha, ponto compatível com a literatura que recomenda avaliação multidimensional e auditoria de amostras em dados sintéticos sensíveis Alaa et al. (2022), Emam et al. (2022), Kaabachi et al. (2025).

Uma terceira contribuição foi a consolidação de um conjunto de protocolos complementares de validação. S1, S2, S3, S3SHAP, S4, S5, S6, S7 e EC avaliaram dimensões distintas do modelo, incluindo fidelidade estatística, inferência condicional, utilidade preditiva interna, explicabilidade, limiares, sensibilidade, casos-limite, fidelidade topológica e plausibilidade clínica. Essa combinação permitiu caracterizar não apenas os pontos fortes do gerador, mas também suas fragilidades, em consonância com propostas recentes que tratam avaliação de dados sintéticos tabulares como um problema de múltiplos eixos Hernandez et al. (2025), Boni, Junior e Costa (2025), Chundawat et al. (2022).

6.3 Síntese dos Achados

Na execução oficial do Core11, com $n = 10000$, os protocolos indicaram boa aderência ao modelo proposto: S1 aprovou 7/7 testes, S2 aprovou 7/7 casos, o Kappa médio em S3 foi de

0,9445, a Distância de Hellinger aprovou 11/11 variáveis e o PCD-MAD foi de 0,0088. Esses resultados sustentaram o Core11 como prova inicial da arquitetura.

Na execução oficial do Core18, também com $n = 10000$, a expansão manteve resultados fortes: S1 aprovou 7/7 testes, S2 aprovou 14/14 casos, o Kappa médio em S3 foi de 0,9209, a Distância de Hellinger aprovou 18/18 variáveis e o PCD-MAD foi de 0,0097. Esses achados indicam que a expansão para 18 variáveis preservou propriedades probabilísticas e topológicas importantes.

Ao mesmo tempo, os resultados críticos foram fundamentais para a interpretação da pesquisa. O S3SHAP não confirmou alinhamento satisfatório entre importância explicativa e pesos normativos; o S4 indicou divergência entre o limiar ótimo e o limiar normativo; o S5 apontou instabilidade de limiar; e o protocolo EC identificou 3686 registros com ao menos uma violação, correspondendo a 36,9% da base Core18. A EC-01, incorporada na versão final, apresentou 236 violações, equivalentes a 2,36% dos registros.

Esses achados não anulam a contribuição da dissertação. Pelo contrário, reforçam sua maturidade metodológica. O trabalho não apenas apresentou um gerador sintético com bons indicadores agregados, mas também demonstrou onde esse gerador ainda falha em termos de plausibilidade individual. Em saúde, essa transparência é indispensável.

6.4 Limitações

A principal limitação é a ausência de validação com dados reais. A dissertação não realizou TSTR, não comparou os registros sintéticos com prontuários hospitalares e não avaliou desempenho prospectivo em ambiente assistencial. Portanto, os resultados devem ser interpretados como validação interna em ambiente de simulação, e não como evidência de validade clínica externa.

Outra limitação está relacionada à natureza knowledge-driven das CPTs. Embora essa abordagem seja adequada ao cenário de *cold start*, ela depende de decisões de elicitação, curadoria e parametrização. Nem todas as probabilidades possuem o mesmo grau de ancoragem empírica. Em versões futuras, essas CPTs poderão ser refinadas com dados reais, consenso formal de especialistas ou métodos híbridos de calibração.

Também é necessário reconhecer que os *edit checks* foram aplicados como auditoria pós-geração. Eles identificam violações e limites de plausibilidade, mas não removem automaticamente registros, não alteram CPTs e não executam reamostragem condicionada. Assim, a base final pode conter linhas sintéticas clinicamente discutíveis, que devem ser interpretadas como achados metodológicos e não como registros prontos para uso assistencial.

Por fim, a dissertação encerrou sua contribuição experimental no Core18. O Core25 e o instrumento mais amplo de variáveis de alta segura neonatal permanecem como horizonte de

expansão, mas não foram tratados como modelos implementados, executados ou validados nesta versão do trabalho.

6.5 Trabalhos Futuros

Como continuidade natural, recomenda-se a calibração futura do modelo com bases reais de recém-nascidos, desde que disponíveis sob condições éticas, regulatórias e institucionais adequadas. Essa etapa permitiria aplicar TSTR, comparar o comportamento sintético com dados observados e estimar empiricamente parte das CPTs.

Outra frente importante é o desenvolvimento de mecanismos ativos de controle de plausibilidade clínica. Os resultados do protocolo EC indicam que futuras versões podem explorar filtros pós-geração, rejeição automática de amostras, reamostragem condicionada ou incorporação de restrições adicionais diretamente nas CPTs. Qualquer uma dessas estratégias deverá ser acompanhada de nova avaliação estatística e topológica, pois a remoção de registros pode alterar distribuições e dependências.

Também se recomenda ampliar a validação qualitativa por especialistas. Um painel de neonatologistas, enfermeiros neonatais ou profissionais envolvidos na alta segura poderia revisar narrativas clínicas derivadas dos registros sintéticos, avaliando plausibilidade, coerência e utilidade educacional. Essa etapa deve ser tratada como validação futura, não como evidência já produzida nesta dissertação.

A expansão para Core25 ou para o conjunto normativo mais amplo de variáveis também constitui caminho futuro. Essa expansão exigirá novas arestas, novas CPTs, novos *edit checks*, revisão da estrutura de escore e nova rodada completa de validação. A experiência do Core18 sugere que aumentar o número de variáveis amplia a cobertura clínica, mas também torna mais visíveis os desafios de plausibilidade individual.

Por fim, trabalhos futuros podem explorar integração com ambientes de simulação, ferramentas de ensino, geração de casos clínicos fictícios e apoio ao desenvolvimento de modelos de IA em saúde neonatal. Também podem investigar extensões para dados longitudinais, séries temporais e sinais fisiológicos contínuos, dimensões relevantes em saúde, mas deliberadamente fora do escopo tabular e transversal desta dissertação Miletic e Sariyar (2026). Tais aplicações, entretanto, devem preservar a distinção entre uso educacional ou metodológico e uso clínico assistencial direto.

6.6 Encerramento

Esta dissertação demonstrou que uma abordagem orientada por conhecimento, implementada por Redes Bayesianas, pode gerar dados sintéticos neonatais auditáveis em cenário de ausência de dados reais. O Core11 confirmou a viabilidade inicial da arquitetura, enquanto o

Core18 mostrou que a metodologia pode ser expandida para um conjunto mais amplo de variáveis clínicas, preservando propriedades estatísticas e topológicas relevantes.

Ao mesmo tempo, os resultados evidenciaram que a geração sintética em saúde exige cautela. A coerência probabilística agregada não garante plausibilidade clínica individual plena, e a ausência de validação externa impede qualquer afirmação de uso assistencial direto. Assim, a contribuição central do trabalho está em oferecer um pipeline transparente, reprodutível e criticamente auditável para iniciar o desenvolvimento de dados sintéticos neonatais em contexto de *cold start*.

Em síntese, o estudo não entrega um sistema clínico pronto para decisão de alta, mas um artefato metodológico para pesquisa, simulação e desenvolvimento responsável. Essa distinção é essencial: o valor da proposta está justamente em mostrar como gerar, validar e questionar dados sintéticos antes de qualquer aproximação com uso clínico real.

Referências

ALAA, A. M. et al. How faithful is your synthetic data? sample-level metrics for evaluating and auditing generative models. *arXiv preprint arXiv:2102.08921*, 2022. Citado 8 vezes nas páginas 28, 36, 41, 65, 71, 77, 96 e 103.

ALMEIDA, M. F. B. d.; GUINSBURG, R. *Reanimação do recém-nascido maior ou igual a 34 semanas em sala de parto: Diretrizes 2026 da Sociedade Brasileira de Pediatria*. [S.l.], 2026. Citado 3 vezes nas páginas 39, 50 e 62.

ALUR, R. et al. Auditing for human expertise. *arXiv preprint arXiv:2306.01646*, 2023. Disponível em: <https://arxiv.org/abs/2306.01646>. Citado na página 40.

ARAUJO, C. M. M. O. et al. Critérios relacionados à alta hospitalar segura do recém-nascido: Uma revisão integrativa. *Enfermería: Cuidados Humanizados*, v. 12, n. 2, p. e3198, 2023. Citado 14 vezes nas páginas 23, 27, 31, 32, 33, 39, 43, 49, 70, 73, 74, 75, 82 e 83.

BATISTA, A. F. M. et al. Neonatal mortality prediction with routinely collected data: a machine learning approach. *BMC Pediatrics*, v. 21, p. 322, 2021. Citado 6 vezes nas páginas 22, 34, 65, 70, 75 e 82.

BEIRANVAND, S. et al. The effects of skin-to-skin contact on temperature and breastfeeding in newborns. *International Journal of Pediatrics*, 2014. Citado na página 32.

BELETEW, B. et al. Prevalence and associated factors of neonatal hypothermia in ethiopia: a systematic review and meta-analysis. *BMC Pediatrics*, 2020. Citado na página 32.

BERNARDINO, P. A. et al. Abordagens e eficácia da inteligência artificial na predição de fatores de risco para sepse neonatal. *Revista Eletrônica Acervo Saúde*, v. 24, n. 10, p. e18334, 2024. Citado 6 vezes nas páginas 22, 34, 43, 65, 70 e 81.

BONI, M.; JUNIOR, I.; COSTA, R. Hy-synergy: geração sintética de dados tabulares em saúde guiada por diagnóstico local. In: . [S.l.: s.n.], 2026. p. 1098–1109. Citado 2 vezes nas páginas 71 e 77.

BONI, M. H. L. de; JUNIOR, I. G. S.; COSTA, R. M. d. Tabular data augmentation using artificial intelligence: A systematic review and taxonomic framework. *IEEE Access*, v. 13, p. 138950–138969, 2025. Citado 16 vezes nas páginas 28, 35, 36, 37, 43, 65, 71, 77, 85, 94, 97, 98, 99, 100, 102 e 103.

Brasil. Ministério da Saúde. *Portaria nº 930, de 10 de maio de 2012: define as diretrizes e objetivos para a organização da atenção integral e humanizada ao recém-nascido grave ou potencialmente grave*. Brasília, DF, 2012. Citado na página 32.

Brasil. Ministério da Saúde. *Atenção à Saúde do Recém-Nascido: Guia para os Profissionais de Saúde*. Brasília, DF, 2014. Citado 6 vezes nas páginas 23, 32, 39, 41, 50 e 51.

Brasil. Ministério da Saúde. *Portaria nº 1.130, de 5 de agosto de 2015: institui a Política Nacional de Atenção Integral à Saúde da Criança*. Brasília, DF, 2015. Citado 3 vezes nas páginas 32, 33 e 50.

Brasil. Ministério da Saúde. *Portaria nº 2.068, de 21 de outubro de 2016: institui diretrizes para a organização da atenção integral e humanizada à mulher e ao recém-nascido no Alojamento Conjunto*. Brasília, DF, 2016. Citado 5 vezes nas páginas 22, 27, 31, 32 e 50.

Brasil. Ministério da Saúde. *Atenção humanizada ao recém-nascido: Método Canguru: manual técnico*. 3. ed. Brasília, DF, 2017. Citado na página 5.

CASTRO, T. d. S.; SANTOS, E. B. d. Redes bayesianas para previsão de valores de ações: aplicando os algoritmos k2 e pc. *Universidade Federal de São João del-Rei – UFSJ*, 2023. Citado 5 vezes nas páginas 36, 37, 40, 42 e 52.

CHEN, R. J. et al. Synthetic data in machine learning for medicine and healthcare. *Nature Biomedical Engineering*, v. 5, n. 6, p. 493–497, 2021. Citado 9 vezes nas páginas 22, 24, 31, 33, 34, 43, 45, 70 e 78.

CHUNDAWAT, V. S. et al. Tabsyndex: A universal metric for robust evaluation of synthetic tabular data. *arXiv preprint arXiv:2207.05295*, 2022. Citado 6 vezes nas páginas 36, 65, 71, 77, 94 e 103.

EMAM, K. E. et al. Utility metrics for evaluating synthetic health data generation methods: Validation study. *JMIR Medical Informatics*, v. 10, n. 4, p. e35734, 2022. Citado 20 vezes nas páginas 28, 36, 42, 43, 49, 61, 65, 71, 72, 73, 74, 83, 91, 94, 96, 97, 98, 99, 100 e 103.

FLORES, C. D. et al. Sr-bayes: um framework para criação de sistemas de apoio à decisão clínica baseados em redes bayesianas. *Anais Estendidos do XXIII Simpósio Brasileiro de Computação Aplicada à Saúde (SBCAS)*, SBC, p. 186–191, 2023. Citado 16 vezes nas páginas 23, 24, 27, 31, 33, 37, 38, 40, 42, 43, 51, 65, 72, 73, 81 e 83.

GELATTI, G. J.; RODRIGUES, P. P.; CARVALHO, A. C. P. L. F. de. Detecção de anomalia através da comparação de modelos representativos. *Instituto de Ciências Matemáticas e de Computação (ICMC) / Faculdade de Medicina da Universidade do Porto*, 2021. Citado na página 37.

GIUFFRè, M.; SHUNG, D. L. Harnessing the power of synthetic data in healthcare: innovation, application, and privacy. *npj Digital Medicine*, Nature Publishing Group, v. 6, n. 186, 2023. Citado 13 vezes nas páginas 35, 41, 45, 65, 71, 72, 73, 80, 83, 97, 98, 99 e 100.

GONCALVES, A. et al. Generation and evaluation of synthetic patient data. *BMC Medical Research Methodology*, v. 20, n. 108, 2020. Citado 28 vezes nas páginas 23, 24, 25, 31, 34, 35, 36, 37, 38, 39, 40, 41, 42, 43, 45, 47, 49, 61, 65, 71, 72, 73, 74, 76, 82, 83, 101 e 102.

GONZALES, A.; GURUSWAMY, G.; SMITH, S. R. Synthetic data in health care: A narrative review. *PLOS Digital Health*, v. 2, n. 1, p. e0000082, 2023. Citado 3 vezes nas páginas 43, 65 e 71.

HERNANDEZ, M. et al. Synthetic data generation for tabular health records: A systematic review. *Neurocomputing*, v. 493, p. 28–45, 2022. Citado 8 vezes nas páginas 29, 35, 65, 71, 72, 73, 76 e 82.

HERNANDEZ, M. et al. Comprehensive evaluation framework for synthetic tabular data in health: fidelity, utility and privacy analysis of generative models with and without privacy guarantees. *Frontiers in Digital Health*, v. 7, p. 1576290, 2025. Citado 23 vezes nas páginas 36, 41, 42, 43, 48, 61, 65, 71, 72, 73, 74, 83, 85, 91, 94, 96, 97, 98, 99, 100, 101, 102 e 103.

HITTMEIR, M.; EKELHART, A.; MAYER, R. On the utility of synthetic data: An empirical evaluation on machine learning tasks. In: *Proceedings of the 14th International Conference on Availability, Reliability and Security*. [S.l.: s.n.], 2019. p. 1–6. Citado 3 vezes nas páginas 61, 99 e 100.

Instituto Nacional de Saúde da Mulher, da Criança e do Adolescente Fernandes Figueira. *Alta segura da mãe e do bebê*. 2020. Portal de Boas Práticas em Saúde da Mulher, da Criança e do Adolescente. Citado 3 vezes nas páginas 27, 32 e 33.

JORDON, J. et al. Synthetic data – what, why and how? *arXiv preprint arXiv:2205.03257*, 2022. Citado 6 vezes nas páginas 23, 35, 45, 71, 78 e 102.

KAABACHI, B. et al. A scoping review of privacy and utility metrics in medical synthetic data. *npj Digital Medicine*, v. 8, n. 60, 2025. Citado 14 vezes nas páginas 23, 35, 36, 42, 43, 45, 71, 72, 73, 79, 97, 98, 100 e 103.

KAUR, D. et al. Application of bayesian networks to generate synthetic health data. *Journal of the American Medical Informatics Association (JAMIA)*, v. 28, n. 4, p. 801–811, 2021. Citado 22 vezes nas páginas 23, 24, 27, 31, 33, 35, 36, 37, 38, 40, 41, 42, 43, 49, 51, 65, 72, 73, 74, 80, 83 e 84.

KITCHENHAM, B. *Procedures for Performing Systematic Reviews*. Keele, UK, 2004. Citado na página 65.

KWOK, T. C. et al. Application and potential of artificial intelligence in neonatal medicine. *Seminars in Fetal and Neonatal Medicine*, Elsevier, v. 27, p. 101346, 2022. Citado 8 vezes nas páginas 22, 33, 34, 65, 70, 74, 82 e 84.

LANDIS, J. R.; KOCH, G. G. The measurement of observer agreement for categorical data. *Biometrics*, v. 33, n. 1, p. 159–174, 1977. Citado 2 vezes nas páginas 61 e 91.

LUCCHESE, I. et al. Aplicativo “nasci bem” para profissionais de saúde e familiares de recém-nascidos: construção, validação e avaliação. *Revista Latino-Americana de Enfermagem*, v. 32, p. e4261, 2024. Citado 3 vezes nas páginas 33, 70 e 81.

MILETIC, M.; SARIYAR, M. Synthetic data generation methods for longitudinal and time series health data: a systematic review. *BMC Medical Informatics and Decision Making*, v. 26, n. 30, 2026. Citado 7 vezes nas páginas 29, 37, 43, 65, 72, 80 e 105.

MURTAZA, H. et al. Synthetic data generation: State of the art in health care domain. *Computer Science Review*, v. 48, p. 100546, 2023. Citado 17 vezes nas páginas 23, 24, 25, 29, 31, 35, 36, 38, 43, 65, 71, 72, 73, 78, 82, 83 e 84.

NEVES, L.; JUNIOR, A.; FRANCO, R. Análise do impacto de dados sintéticos para modelos segmentadores de pólipos adenomatosos em colonoscopia. In: . [S.l.: s.n.], 2026. p. 1253–1264. Citado 2 vezes nas páginas 29 e 81.

NISEVIC, M.; MILOJEVIC, D.; SPAJIC, D. Synthetic data in medicine: Legal and ethical considerations for patient profiling. *Computational and Structural Biotechnology Journal*, Elsevier, v. 28, p. 190–198, 2025. Citado 16 vezes nas páginas 22, 24, 27, 34, 35, 43, 65, 70, 71, 72, 74, 80, 83, 97, 98 e 99.

NORORI, N. et al. Addressing bias in big data and ai for health care: A call for open science. *Patterns*, v. 2, n. 10, p. 100347, 2021. Citado na página 34.

Organização Pan-Americana da Saúde; Brasil. Ministério da Saúde. *AIDPI Neonatal: Manual de Atenção Integrada às Doenças Prevalentes na Infância*. Brasília, DF, 2014. Citado 4 vezes nas páginas 32, 39, 50 e 51.

PEZOULAS, V. C. et al. Synthetic data generation methods in healthcare: A review on open-source tools and methods. *Computational and Structural Biotechnology Journal*, Elsevier, v. 23, p. 2892–2910, 2024. Citado na página 79.

QUEIROZ, I. M. et al. Aspectos relacionados à alta precoce do recém-nascido: revisão integrativa. *Revista Eletrônica Acervo Saúde*, n. 34, p. e1338, 2019. Citado 5 vezes nas páginas 31, 32, 43, 49 e 70.

RAJOTTE, J.-F. et al. Synthetic data as an enabler for machine learning applications in medicine. *iScience*, v. 25, n. 11, p. 105331, 2022. Citado 6 vezes nas páginas 22, 27, 34, 36, 47 e 78.

RANKIN, D. et al. Reliability of supervised machine learning using synthetic data in health care: Model to preserve privacy for data sharing. *JMIR Medical Informatics*, v. 8, n. 7, p. e18910, 2020. Citado 7 vezes nas páginas 48, 61, 73, 85, 98, 99 e 100.

SANTOS, J. L. S.; SILVA, G. J. F. da; SILVA, J. C. da. Redes bayesianas para geração de dados totalmente sintéticos para alta do recém-nascido: Uma proposta metodológica orientada a conhecimento. In: *Anais do Simpósio Brasileiro de Computação Aplicada à Saúde (SBCAS)*. [S.l.: s.n.], 2026. Citado 20 vezes nas páginas 23, 27, 29, 31, 33, 35, 37, 38, 39, 40, 41, 42, 43, 65, 70, 73, 74, 82, 83 e 84.

SILVA, C. T. d. S. et al. Requisitos para construção de aplicativo para a alta e transição de cuidados do recém-nascido. *Revista Contexto & Saúde*, v. 24, n. 49, p. e15636, 2024. Citado 17 vezes nas páginas 22, 23, 27, 31, 32, 33, 37, 39, 43, 49, 50, 70, 73, 75, 82, 83 e 84.

SILVA, C. T. S. et al. Requirements for building an application for newborn discharge and care transition. *Revista Contexto & Saúde*, v. 24, n. 49, p. e15636, 2024. Citado 3 vezes nas páginas 32, 33 e 75.

Sociedade Brasileira de Pediatria. *Nascimento Seguro*. [S.l.], 2018. Citado 2 vezes nas páginas 31 e 32.

Sociedade Brasileira de Pediatria. *Recomendações para alta hospitalar do recém-nascido termo potencialmente saudável*. [S.l.], 2020. Citado 5 vezes nas páginas 23, 27, 31, 32 e 33.

Sociedade Brasileira de Pediatria. *Recomendações para alta hospitalar do Recém-Nascido Termo Potencialmente Saudável*. [S.l.], 2021. Citado 13 vezes nas páginas 22, 23, 27, 31, 32, 33, 39, 41, 43, 50, 51, 73 e 76.

SOUZA, A. K. A.; BRANDãO, A. C. Recomendações destinadas aos profissionais da saúde: critérios para a alta segura do recém-nascido. *Revista Contribuciones a las Ciencias Sociales*, 2023. Citado na página 76.

TUCKER, A. et al. Generating high-fidelity synthetic patient data for assessing machine learning healthcare software. *npj Digital Medicine*, v. 3, n. 147, 2020. Citado 7 vezes nas páginas 35, 36, 45, 47, 71, 79 e 83.

Universidade Federal da Bahia. Escola de Enfermagem. Comitê de Ética em Pesquisa. *Parecer Consubstanciado do CEP nº 8.484.157: Desenvolvimento e Validação de Aplicativo para Alta Segura do Recém-Nascido para Equipe de Saúde*. Salvador: [s.n.], 2026. CAAE nº 64756722.6.0000.5531. Pesquisadora responsável: Camila Tahis dos Santos Silva. Aprovado pelo CEP/EEUFBA em 03 de junho de 2026. Citado na página 47.

World Health Organization. *WHO recommendations on maternal and newborn care for a positive postnatal experience*. Geneva, 2022. Citado 6 vezes nas páginas 23, 32, 33, 43, 50 e 51.

YALE, A. et al. Generation and evaluation of privacy preserving synthetic health data. *Neurocomputing*, v. 416, p. 244–255, 2020. Citado 5 vezes nas páginas 35, 45, 71, 79 e 83.

Apêndices

APÊNDICE A – Síntese das Tabelas de Probabilidade Condicional do Core18

Este apêndice apresenta uma síntese consolidada das Tabelas de Probabilidade Condicional (CPTs) que compõem o Core18 (M18), com o objetivo de oferecer ao leitor uma visão estrutural do papel metodológico de cada variável e da regra de validação a ela associada, sem reproduzir integralmente os valores numéricos célula a célula. O detalhamento completo das CPTs — incluindo os valores de probabilidade e a classificação por camada de rastreabilidade — encontra-se no documento técnico de parametrização das CPTs, tratado no Apêndice D como artefato documental completo.

A coluna "Pais na rede"reproduz a topologia de dependências implementada no código-fonte do gerador (`modelo_bn_dissertacao.py`), evitando qualquer divergência entre a documentação e a implementação computacional. Os rótulos dos estados de cada variável foram normalizados graficamente para leitura (por exemplo, "Não Apresenta", "Espontâneas", "Hipertensão") e correspondem, sem acentuação, aos identificadores ASCII utilizados internamente no código (por exemplo, `NaoApresenta`, `Espontaneas`, `Hipertensao`). Todas as CPTs foram submetidas à rotina de verificação de fechamento probabilístico (*validar_cpt*), que confirma, para cada configuração dos nós-pai, que a soma das probabilidades sobre os estados do nó-filho é igual a 1.

As onze primeiras variáveis do quadro abaixo (IG a Vacina) pertencem ao Core Set original (Core11), cuja topologia e parametrização foram publicadas no artigo aceito no SBCAS 2026. As sete variáveis subsequentes (Eliminações a Sono) constituem a expansão biofisiológica introduzida no Core18.

Tabela 18 – Síntese das CPTs do Core18

Variável	**Pais na rede**	**Estados**	**Papel metodológico**	**Regra/validação associada**
IG	Nó raiz (sem pais)	Termo, Prematuro, Extremo	Variável estrutural de maior peso normativo; único nó raiz do Core11 (no Core18, Coto Umbilical constitui um segundo nó raiz, local e desconectado de IG), condicionando diretamente sete variáveis a jusante (Peso, Apgar, Oxigenação, Respiração, FC, Temperatura, Triagens) e, junto de Peso, Icterícia.	*validar_cpt*; cortes normativos conforme Silva (2024).
Peso	IG	Adequado, Baixo, Muito Baixo	Covariável de maturidade nutricional, filha de IG; nó-pai de Amamentação, Icterícia e Vacina no Core11.	*validar_cpt*; parametrização publicada no SBCAS 2026.
Apgar	IG	Deprimido, Limítrofe, Normal	Indicador de vitalidade ao nascimento, filho direto de IG.	*validar_cpt*; parametrização publicada no SBCAS 2026.
Amamentação	Peso	Ineficaz, Parcial, Eficaz	Indicador de estabilidade para via oral, filho direto de Peso (não de IG).	*validar_cpt*; parametrização publicada no SBCAS 2026.

(continuação)

Variável	**Pais na rede**	**Estados**	**Papel metodológico**	**Regra/validação associada**
Oxigenação	IG	Hipóxica, Normal	Indicador de estabilidade respiratória, filho direto de IG; nó-pai de Sinais de Alerta no Core18.	*validar_cpt*; parametrização publicada no SBCAS 2026.
Respiração	IG	Taquipneico, Bradipneico, Normal	Indicador do padrão ventilatório, filho direto de IG; nó-pai de Sinais de Alerta no Core18.	*validar_cpt*; parametrização publicada no SBCAS 2026.
FC (Frequência Cardíaca)	IG	Anormal, Limítrofe, Normal	Indicador de estabilidade cardiovascular, filho direto de IG; nó-pai de Sinais de Alerta e de Níveis Pressóricos (PA) no Core18.	*validar_cpt*; parametrização publicada no SBCAS 2026.
Temperatura	IG	Alterada, Limítrofe, Normal	Indicador de estabilidade térmica, filho direto de IG.	*validar_cpt*; parametrização publicada no SBCAS 2026.
Icterícia	IG, Peso	Grave, Moderada, Ausente	Indicador de risco hemolítico e de hiperbilirrubinemia, com dois pais diretos (IG e Peso).	*validar_cpt*; parametrização publicada no SBCAS 2026.
Triagens (Neonatais)	IG	Encaminhado, Agendado, Realizado	Variável de auditoria normativa, filha direta de IG; funciona como *hard stop* sobre o desfecho de alta, independentemente do escore global.	*validar_cpt*; parametrização publicada no SBCAS 2026.

(continuação)

Variável	**Pais na rede**	**Estados**	**Papel metodológico**	**Regra/validação associada**
Vacina	Peso	Sem Previsão, Agendado, Vacinado	Variável com zero estrutural: $P(\text{Vacinado} \mid \text{MuitoBaixo}) = 0{,}00$, refletindo a contraindicação de esquema vacinal completo em recém-nascido de muito baixo peso.	Zero estrutural aplicado durante a amostragem (*hard-coded* no gerador), distinto de um edit check pós-geração.
Eliminações	IG, Peso	Espontâneas, Insuficiente, Ausentes	Indicador de prontidão gastrointestinal/ renal introduzido no Core18.	*validar_cpt*; camada de rastreabilidade e fontes detalhadas no documento de parametrização das CPTs do Core18.
Exame Físico	IG	Normal, Alterado Sem Risco, Alterado Cirúrgico	Indicador de integridade anatômica global; a categoria Alterado Cirúrgico é referenciada em edit check associado ao desfecho de alta.	*validar_cpt*; camada de rastreabilidade e fontes detalhadas no documento de parametrização das CPTs do Core18.
Sinais de Alerta	Respiração, FC, Oxigenação	Não Apresenta, Esporádico, Frequente	Variável concebida como manifestação (filho) da instabilidade cardi-orrespiratória, evitando tratá-la como nó irmão dessas variáveis.	*validar_cpt*; camada de rastreabilidade e fontes detalhadas no documento de parametrização das CPTs do Core18.

(continuação)

Variável	**Pais na rede**	**Estados**	**Papel metodológico**	**Regra/validação associada**
PA (Níveis Pressóricos)	IG, FC	Normal, Hipertensão, Hipotensão	Indicador de estabilidade hemodinâmica; a categoria Hipotensão é referenciada em edit check associado ao desfecho de alta.	*validar_cpt*; parametrização com cobertura diferenciada por subgrupo de idade gestacional, detalhada no documento correspondente.
Coto (Coto Umbilical)	Nó raiz local (sem pais)	Higienizado, Inflamação, Sangrante	Variável de baixa dependência causal de IG/Peso, tratada como nó raiz local associado a tempo de vida e cuidado, não à maturidade gestacional.	*validar_cpt*; fonte epidemiológica detalhada no documento de parametrização das CPTs do Core18.
Pele (Integridade da Pele)	IG, Peso	Íntegra, Risco de Dermatite, Lesão	Indicador de fragilidade cutânea, associado à maturidade gestacional e ao peso ao nascer.	*validar_cpt*; camada de rastreabilidade e fontes detalhadas no documento de parametrização das CPTs do Core18.
Sono	IG	Adequado, Reduzido, Insuficiente	Indicador de maturidade neurológica, associado ao ciclo de sono conforme a idade gestacional.	*validar_cpt*; camada de rastreabilidade e fontes detalhadas no documento de parametrização das CPTs do Core18.

Nota metodológica. A tabela acima reproduz a topologia de pais implementada no código-fonte do gerador para as variáveis do Core11 (IG→Peso, IG→Apgar, IG→Oxigenação, IG→Respiração, IG→FC, IG→Temperatura, IG→Triagens,
Peso→Amamentação, Peso→Icterícia, IG→Icterícia, Peso→Vacina); apenas os rótulos dos

estados foram normalizados graficamente (acentuação) em relação aos identificadores ASCII do código, sem alteração de significado clínico. A classificação por camada de rastreabilidade (Valor Ancorado, Direção Ancorada ou Consenso Clínico) de cada variável do Core18 é declarada de forma detalhada no documento técnico de parametrização das CPTs, evitando-se, neste apêndice, a repetição de referências bibliográficas específicas que não estejam plenamente integradas à revisão de literatura do texto principal.

APÊNDICE B – Síntese da Matriz de Justificação das Arestas da Rede Bayesiana

Este apêndice sintetiza a Matriz de Justificação das Arestas do Core18, que assegura que nenhuma dependência causal da Rede Bayesiana foi introduzida de forma arbitrária, mas sim fundamentada em conhecimento clínico e, sempre que disponível, em evidência científica identificável. A matriz completa, incluindo o cálculo dos índices de consistência estrutural e as referências bibliográficas específicas de cada aresta, está descrita no documento técnico correspondente (Apêndice D).

A Tabela 19 reproduz, na primeira parte, as arestas do Core11 exatamente como implementadas no código-fonte do gerador, já publicadas e justificadas no artigo SBCAS 2026 e não reavaliadas neste apêndice. Na segunda parte, sintetiza as arestas introduzidas especificamente pela expansão Core18, classificadas segundo o tipo de evidência que as sustenta (Valor Ancorado, Direção Ancorada ou Consenso Clínico). Essas arestas foram registradas como artefatos internos de curadoria clínica, compondo a rastreabilidade metodológica da construção do DAG e das CPTs.

Tabela 19 – Síntese das arestas da Rede Bayesiana (Core11 + Core18)

Aresta	**Tipo de relação**	**Justificativa clínica**	**Função na rede**
Arestas do Core11 (topologia publicada — SBCAS 2026, reproduzida do código-fonte)			
IG → Peso	Consenso Clínico	Relação estrutural entre maturidade gestacional e peso ao nascer.	Nó-pai de Peso.
IG → Apgar	Consenso Clínico	Idade gestacional influencia a vitalidade ao nascimento mensurada pelo escore de Apgar.	Nó-pai de Apgar.
IG → Oxigenação	Consenso Clínico	Menor maturidade gestacional associa-se a maior risco de instabilidade na oxigenação.	Nó-pai de Oxigenação.

(continuação)

Aresta	Tipo de relação	Justificativa clínica	Função na rede
IG → Respiração	Consenso Clínico	Menor maturidade gestacional associa-se a maior instabilidade do padrão ventilatório.	Nó-pai de Respiração.
IG → FC	Consenso Clínico	Maturidade gestacional influencia a estabilidade da frequência cardíaca neonatal.	Nó-pai de FC.
IG → Temperatura	Consenso Clínico	Maturidade gestacional influencia a termorregulação neonatal.	Nó-pai de Temperatura.
IG → Triagens	Consenso Clínico	Maturidade gestacional condiciona o encaminhamento e a viabilidade das triagens neonatais obrigatórias.	Nó-pai de Triagens.
Peso → Amamentação	Consenso Clínico	Peso ao nascer condiciona a maturidade da coordenação sucção-deglutição necessária à amamentação eficaz.	Único nó-pai de Amamentação.
Peso → Icterícia	Consenso Clínico	Peso ao nascer associa-se ao risco de hiperbilirrubinemia neonatal.	Nó-pai de Icterícia, junto de IG.
IG → Icterícia	Consenso Clínico	Maturidade gestacional associa-se ao risco de hiperbilirrubinemia neonatal.	Nó-pai de Icterícia, junto de Peso.
Peso → Vacina	Consenso Clínico	Peso ao nascer determina contraindicações vacinais específicas (BCG, hepatite B) abaixo de determinado limiar.	Sustenta o zero estrutural da variável Vacina.
Arestas introduzidas pela expansão Core18 (em validação clínica)			

(continuação)

Aresta	Tipo de relação	Justificativa clínica	Função na rede
IG → Eliminações	Direção Ancorada	Prematuridade associa-se à imaturidade gastrointestinal e renal, retardando eliminações espontâneas.	Nó-pai de Eliminações, junto de Peso.
Peso → Eliminações	Direção Ancorada	Baixo peso/muito baixo peso associa-se à imaturidade funcional e maior probabilidade de eliminações insuficientes.	Nó-pai de Eliminações, junto de IG.
IG → Exame Físico	Direção Ancorada	Menor maturidade gestacional aumenta a probabilidade de alterações detectáveis no exame físico neonatal.	Único nó-pai de Exame Físico.
Respiração → Sinais de Alerta	Direção Ancorada	Alterações respiratórias podem manifestar sinais gerais de perigo.	Nó-pai de Sinais de Alerta; concebida como manifestação (filho), não como irmã, das variáveis cardiorrespiratórias.
FC → Sinais de Alerta	Direção Ancorada	Instabilidade da frequência cardíaca compõe o quadro de instabilidade cardiorrespiratória que pode gerar sinais de alerta.	Nó-pai de Sinais de Alerta, junto de Respiração e Oxigenação.
Oxigenação → Sinais de Alerta	Direção Ancorada	Hipoxemia relevante pode produzir manifestações observáveis de gravidade neonatal.	Nó-pai de Sinais de Alerta, junto de Respiração e FC.
IG → PA (Níveis Pressóricos)	Direção Ancorada (com cobertura diferenciada por subgrupo de IG)	A maturidade gestacional influencia os níveis pressóricos neonatais; a cobertura da evidência varia por subgrupo de IG, conforme detalhado no documento de rastreabilidade bibliográfica.	Nó-pai de Níveis Pressóricos, junto de FC.

(continuação)

Aresta	**Tipo de relação**	**Justificativa clínica**	**Função na rede**
FC → PA (Níveis Pressóricos)	Consenso Clínico	A frequência cardíaca é utilizada como hipótese de estabilidade hemodinâmica, mantida por elicitação clínica estruturada, sem suporte direto de estudo específico para esta relação.	Nó-pai de Níveis Pressóricos, junto de IG.
IG → Pele (Integridade da Pele)	Direção Ancorada	Prematuridade aumenta a fragilidade cutânea pela imaturidade da barreira epidérmica.	Nó-pai de Integridade da Pele, junto de Peso.
Peso → Pele (Integridade da Pele)	Direção Ancorada	Baixo peso/muito baixo peso aumenta a vulnerabilidade cutânea.	Nó-pai de Integridade da Pele, junto de IG.
IG → Sono	Direção Ancorada	A maturidade neurológica influencia a organização e a duração do sono neonatal.	Único nó-pai de Sono.
Coto (Coto Umbilical)	—	Estado do coto tem baixa dependência causal de IG/Peso, sendo mais associado ao tempo de vida e cuidado do que à maturidade gestacional.	Registrado como nó raiz local da rede, sem arestas de entrada; funciona como variável de auditoria/local.

Nota metodológica. As arestas introduzidas pela expansão Core18 foram documentadas como artefatos internos de curadoria clínica. A fundamentação bibliográfica específica de cada uma (autores, anos e cobertura por subgrupo de idade gestacional) está documentada no artefato completo (Apêndice D), e não é repetida neste apêndice para evitar a citação de referências ainda não plenamente integradas ao capítulo de revisão de literatura.

APÊNDICE C – Síntese dos Edit Checks Clínicos do Core18

Este apêndice sintetiza as 14 regras de *edit check* (EC) empregadas como camada de auditoria de plausibilidade clínica no Core18. É importante esclarecer, de forma explícita, a natureza metodológica desta camada: nesta dissertação, os edit checks foram utilizados como um mecanismo de **auditoria pós-geração** da base sintética, isto é, uma verificação de consistência clínica aplicada *depois* da amostragem produzida pela Rede Bayesiana. Os edit checks não constituem um mecanismo automático de rejeição de registros nem um procedimento de reamostragem incorporado ao pipeline de geração; distinguem-se, assim, dos zeros estruturais (como o de Vacina, no Core11), que atuam *durante* a amostragem e impedem, por construção, a geração do estado clinicamente impossível. O detalhamento completo de cada regra está disponível nos documentos técnicos correspondentes (Apêndice D).

Tabela 20 – Síntese dos edit checks clínicos do Core18

Código	**Regra auditada**	**Interpretação clínica**	**Uso metodológico**
EC-01	Apgar deprimido com sono adequado	Asfixia grave ou depressão neonatal importante é pouco compatível com padrão fisiológico de sono adequado em um recém-nascido clinicamente estável.	Auditoria de consistência clínica pós-geração; não altera CPTs, score, decisão de alta nem processo de amostragem.
EC-02	Temperatura alterada com sinais de alerta ausentes	Hipotermia neonatal relevante tende a produzir resposta sistêmica observável, tornando pouco plausível sua ocorrência sem qualquer sinal de alerta associado.	Auditoria de plausibilidade pós-geração; não implica rejeição automática nem reamostragem.
EC-03	Icterícia grave com sinais de alerta ausentes	Hiperbilirrubinemia precoce grave costuma acompanhar-se de repercussão clínica, tornando improvável sua coexistência com ausência total de sinais de alerta.	Auditoria de plausibilidade pós-geração.

(continuação)

Código	Regra auditada	Interpretação clínica	Uso metodológico
EC-04	Amamentação eficaz com sinais de alerta frequentes	A manutenção de padrão coordenado de sucção e deglutição é pouco compatível com instabilidade clínica sistêmica frequente.	Auditoria de plausibilidade pós-geração.
EC-05	Hipoxemia com respiração normal	Hipoxemia relevante é, em geral, pouco compatível com padrão respiratório normal, ressalvadas exceções fisiopatológicas específicas (documentadas no artefato de validação clínica). A equipe optou por não converter essas exceções em zero estrutural, mantendo-as apenas como ressalva textual.	Auditoria de plausibilidade pós-geração, aplicada de forma geral, sem condicionamento por Idade Gestacional.
EC-06	Taquipneia com amamentação eficaz	Taquipneia importante compromete a coordenação necessária para alimentação por via oral segura, elevando o risco de broncoaspiração.	Auditoria de plausibilidade pós-geração.
EC-09	Sinais de alerta frequentes com sono adequado	Instabilidade clínica frequente tende a interferir na organização neurocomportamental necessária à consolidação de um padrão de sono adequado.	Auditoria de plausibilidade pós-geração.
EC-10	Coto inflamado com temperatura alterada	A coexistência de sinais de infecção do coto umbilical com hipotermia relevante pode sinalizar quadro sistêmico compatível com processo infeccioso ativo.	Auditoria de plausibilidade pós-geração; variável Coto tratada como nó raiz local, sem aresta direta com Temperatura.

(continuação)

Código	**Regra auditada**	**Interpretação clínica**	**Uso metodológico**
EC-11	Lesão de pele com sinais de alerta ausentes	Lesões cutâneas extensas tendem a produzir repercussão sistêmica, tornando pouco plausível sua ocorrência sem qualquer sinal de alerta associado.	Auditoria de plausibilidade pós-geração.
EC-12	Sono insuficiente com amamentação eficaz	Privação relevante de sono tende a comprometer a organização motora-oral necessária para sustentar mamadas eficazes.	Auditoria de plausibilidade pós-geração.
EC-13	Triagens encaminhadas com decisão de alta	As normativas vigentes vedam a alta sem a realização compulsória das triagens neonatais obrigatórias, independentemente do escore global de alta.	Auditoria normativa pós-geração, com caráter de bloqueio clínico-normativo sobre o desfecho de alta.
EC-14	Hipotensão com decisão de alta	Hipotensão neonatal sinaliza instabilidade cardiovascular relevante, sendo incompatível com a indicação de alta, com cortes diferenciados por subgrupo de idade gestacional.	Auditoria normativa pós-geração, com caráter de bloqueio clínico-normativo sobre o desfecho de alta.
EC-15	Sinais de alerta frequentes com Alta Segura	Sinais gerais de perigo indicam necessidade de avaliação urgente, o que é logicamente incompatível com a classificação Alta Segura.	Auditoria de plausibilidade pós-geração; item ainda em processo de validação clínica.

(continuação)

Código	Regra auditada	Interpretação clínica	Uso metodológico
EC-16	Exame físico cirúrgico com Alta Segura	Achados de exame físico que demandam intervenção cirúrgica são, por definição, incompatíveis com a classificação Alta Segura, que pressupõe exame físico normal como pré-requisito.	Auditoria normativa pós-geração; item ainda em processo de validação clínica.

Nota metodológica. O fluxo metodológico adotado é: conhecimento clínico → DAG → CPTs → amostragem bayesiana → edit checks (auditoria) → base sintética. A camada de edit checks atua exclusivamente como instrumento de auditoria e documentação da plausibilidade clínica dos registros gerados, preservando a modelagem probabilística da Rede Bayesiana como núcleo do processo gerador, sem constituir, nesta dissertação, um mecanismo automatizado de rejeição ou reamostragem.

APÊNDICE D – Rastreabilidade dos Artefatos Metodológicos

Este apêndice registra, de forma consolidada, os documentos técnicos produzidos ao longo da pesquisa que sustentam a rastreabilidade metodológica do Core18. Cada artefato é apresentado com seu conteúdo essencial, sua função na dissertação e sua relação com o Core18.

Tabela 21 – Rastreabilidade dos artefatos metodológicos produzidos na pesquisa

Artefato	**Conteúdo**	**Função na dissertação**	**Relação com o Core18**
CPTs_M18_ preenchidas_FINAL.pdf	Tabelas de probabilidade condicional das sete variáveis biofisiológicas novas do Core18, com classificação por camada de rastreabilidade e validação aritmética célula a célula.	Fonte primária da parametrização probabilística do Core18; base do Apêndice A.	Documento de parametrização direta do Core18.
Construcao_CPTs_ FINAL.pdf	Formalização do protocolo de elicitação estruturada em três camadas (bibliográfica, normativa, consenso clínico), e da distinção entre valor e direção ancorados.	Fundamentação metodológica do processo de elicitação de CPTs.	Aplica-se transversalmente às CPTs do Core18.

(continuação)

Artefato	**Conteúdo**	**Função na dissertação**	**Relação com o Core18**
Embasamento_ Normativo_14_NOVAS_ Variaveis_FINAL.pdf	Corte normativo de Silva (2024) e respaldo em diretrizes oficiais para as 14 variáveis de expansão do Core18/M25, incluindo propostas iniciais de pais candidatos no DAG e de combinações candidatas a edit check.	Material de apoio à validação clínica; origem das propostas posteriormente formalizadas na Matriz de Justificação das Arestas e no Apêndice C.	Abrange as sete variáveis do Core18 e as sete variáveis de escopo M25 (não implementadas nesta fase).
Matriz_Justificacao_das_ Arestas_FINAL.pdf	Matriz de Justificação das Arestas, com taxonomia de evidência, índices de consistência estrutural e situação de validação clínica de cada aresta do Core18.	Especificação estrutural da DAG no escopo Core18; base do Apêndice B.	Documento de especificação direta da topologia do Core18.
Ficha_Rastreabilidade_ Bibliografica_ FINAL.pdf	Fonte única de verdade sobre a cobertura populacional (por idade gestacional) de cada citação utilizada em mais de um artefato (Apêndice C, CPTs, edit checks).	Instrumento de auditoria cruzada, evitando tratamento divergente da mesma fonte bibliográfica em documentos distintos.	Regula o uso, por subgrupo de IG, das referências que ancoram CPTs e edit checks do Core18.
Validacao_Clinica_Edit_ Checks_FINAL.pdf	Matriz de validação clínica dos edit checks, com taxonomia de evidência, classificação operacional e fundamentação científica associada.	Camada de documentação da validação clínica pós-geração; base do Apêndice C.	Descreve a camada de auditoria pós-geração aplicada à base sintética do Core18.

(continuação)

Artefato	**Conteúdo**	**Função na dissertação**	**Relação com o Core18**
EditChecks_M18_ sincronizada_FINAL.pdf	Versão sincronizada e atualizada dos edit checks, incluindo a incorporação formal dos itens mais recentes ainda em validação clínica.	Documento operacional de referência para os edit checks do Core18, sincronizado com o documento de validação clínica.	Consolida, em versão mais recente, o conjunto de edit checks sintetizado no Apêndice C.

Nota final. Os apêndices apresentados neste documento constituem **sínteses padronizadas** dos artefatos metodológicos produzidos ao longo da pesquisa, e não reproduções integrais dos documentos técnicos originais. As versões completas de todos os artefatos listados na Tabela 21 — incluindo o detalhamento célula a célula das CPTs, a matriz integral de justificação das arestas e as fichas de validação clínica — poderão ser mantidas em repositório digital ou material suplementar da pesquisa, disponibilizado conforme a política de compartilhamento de dados adotada pelo programa de pós-graduação.

Anexos

ANEXO A – Parecer de Aprovação do Comitê de Ética em Pesquisa (CEP/EEUFBA nº 8.484.157)

Documento de aprovação ética emitido pelo Comitê de Ética em Pesquisa da Escola de Enfermagem da Universidade Federal da Bahia (CEP/EEUFBA), relativo ao projeto guarda-chuva intitulado **"Desenvolvimento e Validação de Aplicativo para Alta Segura do Recém-Nascido para Equipe de Saúde"**, sob o número do Parecer Consubstanciado **8.484.157** e CAAE **64756722.6.0000.5531**.

ESCOLA DE ENFERMAGEM DA UNIVERSIDADE FEDERAL DA BAHIA - UFBA

PARECER CONSUBSTANCIADO DO CEP

DADOS DA EMENDA

Título da Pesquisa: DESENVOLVIMENTO E VALIDAÇÃO DE APLICATIVO PARA ALTA SEGURA DO RECÉM-NASCIDO PARA EQUIPE DE SAÚDE

Pesquisador: Camila Tahis dos Santos Silva

Área Temática:

Versão: 6

CAAE: 64756722.6.0000.5531

Instituição Proponente: Universidade Federal da Bahia - UFBA

Patrocinador Principal: Financiamento Próprio
Financiamento Próprio

DADOS DO PARECER

Número do Parecer: 8.484.157

Apresentação do Projeto:

Segue conforme versão anterior do Protocolo.

Objetivo da Pesquisa:

Segue conforme versão anterior do Protocolo.

Avaliação dos Riscos e Benefícios:

Segue conforme versão anterior do Protocolo.

Comentários e Considerações sobre a Pesquisa:

Segue conforme versão anterior do Protocolo.

Considerações sobre os Termos de apresentação obrigatória:

Termos apresentados sem inadequações.

Recomendações:

Sem recomendações.

Conclusões ou Pendências e Lista de Inadequações:

Sugere-se aprovação.

Considerações Finais a critério do CEP:

Colegiado homologa parecer de aprovação emitido pela relatoria.

Endereço: Rua Augusto Viana S/N 4º andar da Escola de Enfermagem da Universidade Federal da Bahia
Bairro Canela **CEP:** 40.110-907
UF: BA **Município** SALVADOR
Telefone (71)3283-7615 **Fax:** (71)3283-7604 **E-** cepee.ufba@ufba.br



Este parecer foi elaborado baseado nos documentos abaixo relacionados:

Tipo Documento	Arquivo	Postagem	Autor	Situaçã
Informações Básicas do Projeto	PB_INFORMAÇÕES_BÁSICAS_2683227_E1.pdf	22/04/2026 17:56:19		Aceito
Declaração de Pesquisadores	declaracaopesquisadorFULLassinado.pdf	22/04/2026 17:54:57	LUCAS DE OLIVEIRA ARAUJO	Aceito
Brochura Pesquisa	brochuraprojetonovo.pdf	06/03/2026 15:48:57	Camila Tahis dos Santos Silva	Aceito
Cronograma	novocronogramaa.pdf	06/03/2026 15:48:29	Camila Tahis dos Santos Silva	Aceito
Outros	cartajustificativa.pdf	20/01/2026 17:03:08	Camila Tahis dos Santos Silva	Aceito
Cronograma	novoCRONOGRAMAcep.pdf	20/01/2026 17:01:02	Camila Tahis dos Santos Silva	Aceito
Outros	CartaaoCEP2023.pdf	25/02/2023 16:30:20	Camila Tahis dos Santos Silva	Aceito
Brochura Pesquisa	NOVOprojeCEP.pdf	21/02/2023 12:00:14	Camila Tahis dos Santos Silva	Aceito
TCLE / Termos de Assentimento / Justificativa de Ausência	NOVOtcleFASE3.pdf	21/02/2023 11:50:25	Camila Tahis dos Santos Silva	Aceito
TCLE / Termos de Assentimento / Justificativa de Ausência	NOVOtcleFASEI.pdf	21/02/2023 11:49:06	Camila Tahis dos Santos Silva	Aceito
Cronograma	NOVOCRONOGRAMA.pdf	21/02/2023 11:47:00	Camila Tahis dos Santos Silva	Aceito
TCLE / Termos de Assentimento / Justificativa de Ausência	TCLEFASEI.pdf	18/12/2022 16:32:00	Camila Tahis dos Santos Silva	Aceito
Outros	cartaaoCEP.pdf	18/12/2022 16:29:02	Camila Tahis dos Santos Silva	Aceito
TCLE / Termos de Assentimento / Justificativa de Ausência	TCLEFASEIII.pdf	18/12/2022 16:27:40	Camila Tahis dos Santos Silva	Aceito
Brochura Pesquisa	novoprojeto.pdf	18/12/2022 16:26:09	Camila Tahis dos Santos Silva	Aceito
Declaração de concordância	termoCEPufba.pdf	24/10/2022 21:29:46	Camila Tahis dos Santos Silva	Aceito
Outros	Submeter_atualizado_17_05_21.docx	20/10/2022 10:58:01	DIEGO HENRIQUE DE LIMA	Aceito
Folha de Rosto	folhaderosto.pdf	10/10/2022	Camila Tahis dos	Aceito

Endereço: Rua Augusto Viana S/N 4º andar da Escola de Enfermagem da Universidade Federal da Bahia
Bairro Canela **CEP:** 40.110-907
UF: BA **Município** SALVADOR
Telefone (71)3283-7615 **Fax:** (71)3283-7604 **E-** cepee.ufba@ufba.br

Folha de Rosto	folhaderosto.pdf	13:55:45	Santos Silva	Aceito
Projeto Detalhado / Brochura Investigador	Projeto.pdf	30/09/2022 11:25:43	Camila Tahis dos Santos Silva	Aceito
TCLE / Termos de Assentimento / Justificativa de Ausência	TCLEFINAL.pdf	30/09/2022 11:25:26	Camila Tahis dos Santos Silva	Aceito
Declaração de Pesquisadores	pesquisadores.pdf	29/09/2022 22:02:21	Camila Tahis dos Santos Silva	Aceito
Orçamento	orcamento.pdf	29/09/2022 21:49:58	Camila Tahis dos Santos Silva	Aceito

Situação do Parecer:
Aprovado

Necessita Apreciação da CONEP:
Não

SALVADOR, 03 de Junho de 2026

Assinado por:
Paloma de Castro Brandão
(Coordenador(a))