

**UNIVERSIDADE FEDERAL FLUMINENSE**  
**ESCOLA DE ENGENHARIA**  
**DOUTORADO EM SISTEMAS DE GESTÃO SUSTENTÁVEIS**

FERNANDA ABIZETHE DE CARVALHO DUIM

**ANÁLISE BAYESIANA HIERÁRQUICA PARA UMA MODELAGEM DE  
RISCO**

**Orientadores:**

Prof. Dr. Gilson Brito Alves Lima

Prof. Dr. Pauli Adriano de Almada Garcia

Niterói  
2023

**UNIVERSIDADE FEDERAL FLUMINENSE**  
**ESCOLA DE ENGENHARIA**  
**DOCTORADO EM SISTEMAS DE GESTÃO SUSTENTÁVEIS**

FERNANDA ABIZETHE DE CARVALHO DUIM

**ANÁLISE BAYESIANA HIERÁRQUICA PARA UMA MODELAGEM DE  
RISCO**

Documento de Tese de Doutorado apresentado ao Programa de Pós-Graduação, *Stricto Sensu*, em 2023 da Universidade Federal Fluminense, como requisito parcial para o processo de Doutorado em Sistemas de Gestão Sustentáveis. Área de Concentração: Sistemas de Gestão de Sustentabilidade. Linha de Pesquisa: Apoio à Decisão em Organizações Sustentáveis.

Orientadores:

Prof. *DSc.* Gilson Brito Alves Lima  
Prof. *DSc.* Pauli Adriano de Almada Garcia

Niterói  
2023

Ficha catalográfica automática - SDC/BEE  
Gerada com informações fornecidas pelo autor

D873a Duim, Fernanda Abizethe de Carvalho  
Análise Bayesiana Hierárquica para uma Modelagem de Risco  
/ Fernanda Abizethe de Carvalho Duim. - 2023.  
172 f.

Orientador: Gilson Brito Alves Lima.  
Coorientador: Pauli Adriano de Almada Garcia.  
Tese (doutorado)-Universidade Federal Fluminense, Escola de  
Engenharia, Niterói, 2023.

1. Rede Bayesiana Dinâmica. 2. Confiabilidade. 3.  
Gerenciamento de Risco. 4. Modelagem Bayesiana Hierárquica.  
5. Produção intelectual. I. Lima, Gilson Brito Alves,  
orientador. II. Garcia, Pauli Adriano de Almada, coorientador.  
III. Universidade Federal Fluminense. Escola de Engenharia.  
IV. Título.

CDD - XXX

FERNANDA ABIZETHE DE CARVALHO DUIM

**ANÁLISE BAYESIANA HIERÁRQUICA PARA UMA MODELAGEM DE RISCO**

Documento de Tese de Doutorado apresentado ao Programa de Pós-Graduação, *Stricto Sensu*, em 2023 da Universidade Federal Fluminense, como requisito parcial para o processo de Doutorado em Sistemas de Gestão Sustentáveis. Área de Concentração: Sistemas de Gestão de Sustentabilidade. Linha de Pesquisa: Apoio à Decisão em Organizações Sustentáveis.

Aprovada em 05 de Outubro de 2023.

Banca Examinadora:

---

Prof. Dr. Gilson Brito Alves Lima – Orientador  
Universidade Federal Fluminense - UFF

---

Prof. Dr. Pauli Adriano de Almada Garcia – Coorientador  
Universidade Federal Fluminense - UFF

---

Prof. Dr. Annibal Parracho Santanna  
Universidade Federal Fluminense - UFF

---

Prof. Dr. Luiz Octávio Gavião  
Escola Superior de Guerra – ESG

---

Prof. Dr. Rodrigo Goyannes Gusmão Caiado  
Pontifícia Universidade Católica do Rio de Janeiro - PUC-Rio

---

Prof. Dr. Daniel Luiz De Mattos Nascimento  
Universidad de Jaen – UJA Espana

## **AGRADECIMENTOS**

Inicialmente agradeço a Deus, que me proporcionou tantas conquistas e vitórias em minha vida, que me fez chegar até onde me encontro hoje e que a cada dia me capacita para conquistar níveis cada vez mais altos. Ele está comigo a cada caminhar e a cada decisão tomada.

Agradeço posteriormente aos meus pais e irmã, que são o meu porto seguro, por sempre me incentivarem, me ajudarem quando eu precisei e por aguentar cada momento me apoiando e me dando força para nunca desistir dos meus sonhos. Obrigada por sempre acreditarem em mim, e por fazerem tudo para eu ser uma pessoa melhor. Sem vocês eu não estaria onde me encontro hoje, com as bênçãos de Deus. E também ao meu noivo, Danilo Colombo, por ser o meu companheiro de vida, sempre me dando força até nos momentos mais difíceis, me ajudando nas discussões do trabalho, estando ao meu lado e confiando em meu potencial.

Aos professores e orientadores Gilson Brito e Pauli Garcia, por me direcionarem não apenas nesse período de produção da tese, mas também por todos os anos que estamos trabalhando juntos, pela enorme dedicação, paciência e apoio, sendo peças fundamentais no meu crescimento pessoal e profissional.

Agradeço a Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pelo suporte financeiro da bolsa de pesquisa de doutorado, concedida durante o período de desenvolvimento da tese.

Agradeço, de forma especial, ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pelo apoio às atividades da equipe do Projeto de Produtividade em Pesquisa “Investigações e Modelagens por Técnicas de Inteligência Artificial na Gestão Tecnológica de Riscos, Segurança, Meio Ambiente, Manutenção e Confiabilidade Industrial” (PQ 311484/2020-4)

Agradeço, também, Fundação de Amparo à pesquisa do Estado do Rio de Janeiro (FAPERJ), pelo apoio às atividades do Centro de Inteligência Artificial do Estado do Rio de Janeiro aplicado ao setor de Óleo e Gás (CIA-Rio).

## RESUMO

O processo de gerenciamento de risco é uma estratégia utilizada por algumas organizações a fim de controlar a segurança do seu ambiente operacional, por meio da identificação e priorização dos possíveis cenários de perigo. Esse processo envolve a produção de um plano de emergência com ações para mitigação do risco, seguindo uma abordagem qualitativa. Além dessa, outra abordagem é de cunho quantitativo, por meio do estudo da confiabilidade dos sistemas com a construção de um planejamento de manutenção preventiva para aumentar a disponibilidade dos equipamentos e, concomitantemente, a operacionalidade do processo. Esse gerenciamento possibilita que haja um controle do risco e uma redução da probabilidade de falha dos sistemas que são geradores de consequências de magnitude negativa, como vazamentos, explosões, danos ao meio ambiente, *shutdown* do processo, entre outros. Portanto, o estudo da confiabilidade torna-se gerador de valor para as organizações ao colaborar no embasamento quantitativo para as tomadas de decisões estratégicas. Uma técnica utilizada para estudo de confiabilidade é a rede bayesiana, que possui a vantagem de realizar o diagnóstico e prognóstico das probabilidades de falha dos componentes propulsores dos cenários de risco. Para uma análise completa de um cenário de risco com a identificação das causas e das consequências de um evento indesejado, uma alternativa metodológica é o modelo de *bowtie*. Após uma pesquisa bibliográfica foi identificado uma lacuna na literatura referente ao uso do modelo de *bowtie* dinâmico via modelagem bayesiana hierárquica em que é possível estimar os parâmetros de interesse na modelagem de risco, como as taxas de falha e a suas probabilidades, considerando a propagação da incerteza com o uso de fontes não homogêneas de informação como a opinião de especialista e dados de alto nível. Para construir essa modelagem, o *bowtie* dinâmico gerado por uma rede bayesiana dinâmica, foi combinado com a modelagem bayesiana hierárquica para alcançar essa finalidade. Neste aspecto, a pesquisa objetiva a estruturação de um modelo original de *bowtie* dinâmico, por meio da combinação de rede bayesiana dinâmica e modelagem bayesiana hierárquica para se obter os valores de probabilidade de ocorrência das consequências considerando um cenário de escassez de dados e propagação de incerteza. A aplicação da modelagem proposta foi realizada em um cenário de alto impacto do setor de óleo e gás, conhecido como evento de quebra de *riser*. Como os resultados da modelagem desenvolvida são obtidas as probabilidades dos ocorrência do evento indesejado, das barreiras e suas consequências ao longo do tempo, de forma a ajudar na atualização das informações como as taxas de falha, no planejamento de atividades de controle e mitigação dos riscos. Após a modelagem e aplicação, foi identificado que as probabilidades resultantes com esse modelo são mais conservadoras quando comparado com os resultados em que a incerteza não é propagada, o que colabora na tomada de decisões para obter um ambiente mais seguro e reduz a probabilidade de ocorrência de consequências negativas.

**Palavras-Chave:** Confiabilidade, Rede bayesiana Dinâmica, Modelagem Bayesiana Hierárquica, Evento quebra de *riser*, Gerenciamento de Riscos, *Bowtie*.

## ABSTRACT

The risk management process is a strategy used by some organizations to control the safety of their operational environment through the identification and prioritization of potential hazard scenarios. This process involves the production of an emergency plan with actions to mitigate risk, following a qualitative approach. Besides this, another approach is quantitative, through the study of system reliability with the construction of a preventive maintenance plan to increase equipment availability and, concurrently, the operationality of the process. This management enables risk control and a reduction in the probability of failure of systems that generate consequences of negative magnitude, such as leaks, explosions, environmental damage, process shutdown, among others. Therefore, the study of reliability becomes a value generator for organizations by collaborating in the quantitative foundation for strategic decision-making. A technique used for reliability study is Bayesian networks, which have the advantage of diagnosing and prognosticating the failure probabilities of the components driving risk scenarios. For a complete analysis of a risk scenario with the identification of the causes and consequences of an unwanted event, a methodological alternative is the bowtie model. After a literature review, a gap was identified regarding the use of dynamic bowtie modeling via hierarchical Bayesian modeling, which makes it possible to estimate the parameters of interest in risk modeling, such as failure rates and their probabilities, considering the propagation of uncertainty with the use of non-homogeneous sources of information such as expert opinion and high-level data. To construct this modeling, the dynamic bowtie generated by a dynamic Bayesian network was combined with hierarchical Bayesian modeling to achieve this purpose. In this aspect, the research aims to structure an original dynamic bowtie model, through the combination dynamic Bayesian network and hierarchical Bayesian modeling to obtain the probability values of the occurrence of consequences considering a scenario of data scarcity and uncertainty propagation. The application of this proposed modeling was carried out in a high-impact scenario in the oil and gas sector, known as a riser break event. The results obtained in this research are the probabilities of the occurrence of the unwanted event, the barriers, and their consequences over time, to help update information such as failure rates, in the planning of control activities and mitigation of risks. After modeling and application, it was identified that the resulting probabilities with this model are more conservative compared to results where uncertainty is not propagated, which collaborates in decision-making to achieve a safer environment and reduces the probability of occurrence of negative consequences.

**Keywords:** Reliability, Dynamic Bayesian Network, Hierarchical Bayesian Network, Fracture *Riser* Event, Process Safety, Risk Management, Bowtie.

## LISTA DE ILUSTRAÇÕES

<b>Figura 1:</b> Estrutura de uma rede bayesiana.....	25
<b>Figura 2:</b> Estrutura de uma rede bayesiana de exemplo.....	30
<b>Figura 3:</b> Portões lógicos da árvore de falha (A) AND e (b) OR.....	34
<b>Figura 4:</b> Conversão de AF em RB para os portões OR(a) e AND(b).....	34
<b>Figura 5:</b> Conversão de AF em RB para o portão 2:3.....	35
<b>Figura 6:</b> Árvore de evento hipotética.....	36
<b>Figura 7:</b> Exemplo de Árvore de Evento.....	38
<b>Figura 8:</b> Exemplo de árvore de evento.....	40
<b>Figura 09:</b> Rede bayesiana construída pelo exemplo de árvore de evento.....	40
<b>Figura 10:</b> Modelo de transformação do bowtie em rede bayesiana.....	43
<b>Figura 11:</b> Mapa de conversão da árvore de evento em rede bayesiana.....	44
<b>Figura 12:</b> Exemplo de rede bayesiana dinâmica.....	45
<b>Figura 13:</b> Diagrama de transição dos estados dos componentes com múltiplos estados de degradação.....	48
<b>Figura 14:</b> Estrutura gráfica de representação de um modelo hierárquico.....	52
<b>Figura 15:</b> Estrutura lógica do modelo bayesiano hierárquico.....	55
<b>Figura 16:</b> Fluxo do procedimento metodológico.....	62
<b>Figura 17:</b> Estrutura do <i>bowtie</i> para o caso hipotético.....	63
<b>Figura 18:</b> Estrutura da rede bayesiana estática para os eventos básicos.....	67
<b>Figura 19:</b> Estrutura da rede bayesiana estática para o caso hipotético.....	79
<b>Figura 20:</b> Representação Gráfica do processo metodológico.....	87
<b>Figura 21:</b> Estrutura do <i>riser</i> de perfuração.....	95
<b>Figura 22:</b> Árvore de falha para o evento de quebra de <i>riser</i> .....	100
<b>Figura 23:</b> Rede Bayesiana dinâmica para o evento de quebra de <i>riser</i> para 8760 horas.....	100
<b>Figura 24:</b> Árvore de falha das barreiras de segurança (a) Deadman/Autoshear (b) Acústico.....	101
<b>Figura 25:</b> Árvore de Evento para a quebra/fratura de <i>Riser</i> .....	102
<b>Figura 26:</b> Fluxo de informação do método PRISMA.....	131

## LISTA DE TABELAS

<b>Tabela 1:</b> Probabilidades de cada nó dependendo do estado.....	28
<b>Tabela 2:</b> Tabela de probabilidade condicional do nó F.....	28
<b>Tabela 3:</b> Probabilidades de cada nó raiz dependendo do estado.....	30
<b>Tabela 4:</b> Probabilidade condicional do nó C.....	30
<b>Tabela 5:</b> Tabela de probabilidade condicional para a rede bayesiana da árvore de evento.....	41
<b>Tabela 6:</b> Resultado da tabela de probabilidade condicional para a rede bayesiana da árvore de evento.....	41
<b>Tabela 7:</b> Taxa de falha dos eventos básicos e das barreiras de segurança.....	67
<b>Tabela 8:</b> Estrutura lógica da tabela de probabilidade condicional do evento C.....	68
<b>Tabela 9:</b> Tabela de probabilidade condicional do evento C.....	69
<b>Tabela 10:</b> Estrutura lógica da tabela de probabilidade condicional da barreira 1.....	70
<b>Tabela 11:</b> Tabela de probabilidade condicional da barreira 1.....	71
<b>Tabela 12:</b> Estrutura lógica da tabela de probabilidade condicional das consequências.....	72
<b>Tabela 13:</b> Tabela de probabilidade condicional das consequências.....	72
<b>Tabela 14:</b> Probabilidades das relações de transição entre nós consecutivos.....	74
<b>Tabela 15:</b> Relações de transição entre nós consecutivos da inspeção incompleta.....	76
<b>Tabela 16:</b> Valores de probabilidade dos eventos em cada <i>time-slice</i> .....	79
<b>Tabela 17:</b> Probabilidades do evento C, das barreiras de segurança e das consequências em cada <i>time-slice</i> .....	80
<b>Tabela 18:</b> Informações de evidências dos eventos.....	81
<b>Tabela 19:</b> Valores das probabilidades de Falha de A, B e C, das barreiras de segurança e das consequências.....	85
<b>Tabela 20:</b> Resultados obtidos na aplicação da Hipótese 4.....	88
<b>Tabela 21:</b> Sumário dos resultados para as quatro hipóteses.....	91
<b>Tabela 22:</b> Cálculo multiplicativo para cada caminho da árvore de evento.....	102
<b>Tabela 23:</b> Parâmetros de cada evento básico da quebra de <i>riser</i> e das barreiras de segurança.....	103
<b>Tabela 24:</b> Informações de evidências sobre as barreiras de segurança.....	104
<b>Tabela 25:</b> Resultados das distribuições <i>a posteriori</i> das consequências, das barreiras de segurança e do evento iniciador para a segunda hipótese de aplicação.....	104
<b>Tabela 26:</b> Resultados das distribuições <i>a posteriori</i> das consequências, das barreiras de segurança e do evento iniciador para a terceira hipótese de aplicação.....	105
<b>Tabela 27:</b> Resultados das distribuições <i>a posteriori</i> das consequências, das barreiras de segurança e do evento iniciador.....	106
<b>Tabela 28:</b> Tabela resumo de artigos para as palavras-chaves das técnicas de análise de risco.....	130

## LISTA DE QUADROS

<b>Quadro 1:</b> Tabela resumo do estado da arte e lacuna da literatura encontrada.....	18
<b>Quadro 2:</b> Exemplo de Prior e Hiperparâmetros.....	53
<b>Quadro 3:</b> Quadro comparativo das hipóteses do procedimento metodológico.....	64

## LISTA DE GRÁFICOS

<b>Gráfico 1:</b> Comportamento das consequências para a hipótese 3.....	85
<b>Gráfico 2:</b> Comportamento das consequências ao longo dos intervalos (a) Consequência 1, (b) Consequência 2, (c) Consequência 3 e (d) Consequência 4.....	89
<b>Gráfico 3:</b> Gráficos das distribuições <i>a posteriori</i> das consequências, das barreiras de segurança e do evento iniciador para a terceira hipótese de aplicação.....	105
<b>Gráfico 4:</b> Resultados das funções de densidade de probabilidade <i>a posteriori</i> das consequências, das barreiras de segurança e do evento iniciador.....	107

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b>	<b>11</b>
1.1	CONTEXTUALIZAÇÃO	11
1.2	SITUAÇÃO PROBLEMA	13
1.3	OBJETIVO DA PESQUISA	19
1.4	CONTRIBUIÇÃO E ORIGINALIDADE DA PESQUISA	19
1.5	ASPECTOS DA INTERDISCIPLINARIDADE DA PESQUISA	20
1.6	ESTRUTURA DA PESQUISA	21
<b>2</b>	<b>FUNDAMENTAÇÃO TEÓRICA</b>	<b>23</b>
2.1	MODELAGEM DA CONFIABILIDADE VIA REDE BAYESIANA	23
2.1.1	Contextualização	23
2.1.2	Modelagem da Rede Bayesiana	24
2.1.3	Conversão de Rede Bayesiana em Árvore de Falha	32
2.2	MODELAGEM VIA REDE BAYESIANA DINÂMICA	35
2.3	ÁRVORE DE EVENTO	41
2.4	CONVERSÃO DO <i>BOWTIE</i> EM REDE BAYESIANA	48
2.5	INFERÊNCIA BAYESIANA	50
2.5.1	Modelagem Bayesiana Hierárquica	51
2.5.2	Opinião de Especialista	55
<b>3</b>	<b>PROCEDIMENTO METODOLÓGICO</b>	<b>58</b>
3.1	ABORDAGEM METODOLÓGICA	58
<b>4</b>	<b>A PROPOSTA DE APLICAÇÃO DA PESQUISA</b>	<b>87</b>
4.1	<i>RISER</i> DE PERFURAÇÃO E QUEBRA DE <i>RISER</i>	87
4.2	BARREIRA DE SEGURANÇA DO EVENTO DE QUEBRA DE <i>RISER</i>	91
<b>5</b>	<b>ANÁLISE E DISCUSSÃO DOS RESULTADOS</b>	<b>93</b>
<b>6</b>	<b>CONCLUSÃO</b>	<b>104</b>
	<b>REFERÊNCIA BIBLIOGRÁFICA</b>	<b>106</b>
	APÊNDICE 1 – Estado da Arte	120
	APÊNDICE 2 – Estado da Técnica	128
	APÊNDICE 3 – Código da proposta metodológica	133
	APÊNDICE 4 – Código da hipótese caso de aplicação para a Hipótese 3	137
	APÊNDICE 5 – Código da hipótese de aplicação para a Hipótese 4	143

# 1 INTRODUÇÃO

## 1.1 CONTEXTUALIZAÇÃO

O gerenciamento de segurança é formado por ações norteadas por condutas estratégicas e normas regulamentadoras, com o objetivo de prevenir acidentes a partir da identificação e tratamento de risco. A análise e gerenciamento do risco permite identificar, quantificar e gerenciar os riscos das operações de segurança de sistemas (TOLO; ANDREWS, 2022). Alguns exemplos de técnicas qualitativas utilizadas para identificação do risco são: HAZOP (Estudo de Perigo e Operabilidade), FMEA (Análise de Modo de Falha e Efeito), análise preliminar de risco, *What if* e LOPA (Análise de Camadas de Proteção). Outras, quantitativas, como a árvore de evento, a árvore de falha e a rede bayesiana, são usadas para a modelagem de confiabilidade, que tem a finalidade de estimar a probabilidade de não ocorrência de falha durante um período de tempo e sob condições preestabelecidas (NBR 5462). O estudo da confiabilidade gera resultados quantitativos que servem de embasamento para tomadas de decisão sobre as ações de manutenção e operação, com a intenção de reduzir a probabilidade de acidentes graves (ZIO, 2016). As empresas que possuem sistemas operacionais com atividades de alto risco para um possível acidente, interno e externo à organização, buscam realizar ações de gestão de segurança de processo com a finalidade de garantir a sua produção, reduzir os seus riscos e mitigar os seus possíveis prejuízos. Por esse motivo, o estudo do risco e a modelagem da confiabilidade dos sistemas são de interesse das corporações, com o objetivo de, por meio dessa quantificação, dar suporte às tomadas de decisão estratégicas operacionais.

A prevenção de acidente se inicia pela identificação do cenário e, posteriormente, pelo estudo de suas causas, para, assim, alcançar o objetivo de estabelecer ações de controles de segurança a serem aplicadas (ZHANG; ZHANG; HU, 2019; LI; GULDENMUND, 2018; MOHAMMADI *et al.*, 2018). O conceito de barreira de segurança está associado à proteção por meio da prevenção ou mitigação de um evento indesejado, a partir da identificação das ações de controle das causas e consequências do evento, com a finalidade de proteger os ativos, as pessoas e o meio ambiente (SWUSTE *et al.*, 2016; SKOGDALEN; VINNEM, 2012). As barreiras de segurança podem ter duas intenções: proativas ou reativas. As proativas têm a finalidade de funcionar antes da ocorrência do evento indesejado, ou seja, de prevenir; enquanto as reativas são destinadas a funcionar após esse evento, isto é, mitigar. As barreiras proativas buscam

reduzir a possibilidade de ocorrência do acidente, e as reativas são usadas para mitigar ou enfraquecer as consequências de um acidente e limitar as suas propagações (RAUSAND, 2013). A definição e combinação apropriada das barreiras de segurança de um processo colaboram para a redução da probabilidade de ocorrência de uma consequência negativa.

Para as situações em que os processos são compostos por múltiplas camadas de subsistemas e componentes, com o objetivo de desempenhar a função do sistema complexos, frequentemente são sistemas constituídos de uma hierarquia com características de dependência, incerteza, não linearidade e aleatoriedade (YANG *et al.*, 2020; SUN *et al.*, 2021). A relação de dependência explica que a camada superior depende do funcionamento adequado da camada inferior. A incerteza dos dados pode existir no comportamento da falha e na relação entre os componentes, assim como também entre os subsistemas nos diferentes níveis ou entre eles. A não linearidade pode ocorrer de duas maneiras, considerando a degradação dos sistemas hierárquicos em seu tempo contínuo. A primeira é a não linearidade do processo de degradação em cada componente; e a segunda, a não linearidade na relação de dependência entre os elementos de diferentes níveis (ZHANG *et al.*, 2018). A não linearidade entre os elementos de diferentes níveis gera uma incerteza de resultados, pois não é confirmada a relação entre os eventos, o que torna necessário estudar os diferentes cenários. Para o processo de degradação dos componentes, ele também gera uma incerteza em relação ao risco, o que justifica a necessidade de um estudo dinâmico do risco do processo ao longo do ciclo da vida do sistema, a fim de avaliar as suas modificações (ZHANG; WU, 2018). As técnicas para modelagem de sistemas hierárquicos complexos incluem: cadeia de Markov, rede de Petri, árvore de falha e rede bayesiana (WEBER; SIMON; THEILLIOL, 2010; KABIR; PAPADOPOULOS, 2019). Portanto, essas técnicas são adequadas para representar a funcionalidade e calcular a confiabilidade desses tipos de sistemas com muitos subsistemas em camadas.

A rede bayesiana utiliza inferência para a modelagem de confiabilidade no cálculo dos eventos de interesse de um sistema composto por muitos subsistemas. Um possível processo utilizado para esse cálculo é por meio da discretização dos dados, que são contínuos. Entretanto, ao aplicar essa estratégia, é inevitável que haja uma perda de informação sobre o evento, pois há a transformação dos dados, que são contínuos, em discretos, o que conduz a uma estimativa de confiabilidade imprecisa, além da não propagação da incerteza. Esse tipo de situação gera valores distintos da realidade que

podem induzir tomadas de decisões equivocadas (NEIL *et al.*, 2019; AMIN *et al.*, 2021). Portanto, a modelagem de sistemas com dados contínuos sem a discretização e a propagação do erro é uma alternativa para alcançar valores mais fidedignos.

## 1.2 SITUAÇÃO PROBLEMA

O ambiente operacional, em sua complexidade de ações e atividades, precisa ser gerenciado no âmbito de segurança, devido aos seus processos gerarem riscos que comprometem os fatores humanos, econômicos e ambientais da empresa (HADDAD *et al.*, 2011). Por esse motivo, as organizações possuem um zelo em estudar qualitativamente os modos de falha dos sistemas, para poder controlar o risco e definir recomendações para os procedimentos de segurança. A partir da análise de risco, é possível estruturar os cenários viáveis e, assim, montar um plano de segurança. Além do suporte qualitativo, há uma abordagem quantitativa que pode ser modelada, a fim de colaborar na complementação do estudo de risco, ao longo do tempo, baseado em valores (WANG *et al.*, 2008).

O modelo *bowtie* é uma alternativa de método que tem a finalidade de identificar e quantificar a ocorrência de um acidente mediante a circunstância dos eventos básicos e os efeitos gerados pela ocorrência de um evento, denominado de indesejado (AHMED *et al.*, 2019). O *bowtie* é composto por uma estrutura de árvore de falha conectada a uma de árvore de evento, em que a estrutura da árvore de falha contém as causas de ocorrência do evento indesejado, enquanto a árvore de evento contém as barreiras de segurança e as consequências geradas pela combinação de falha e sucesso dessas barreiras (KHAKZAD; KHAN; AMYOTTE, 2013a). Ao realizar a pesquisa bibliográfica, foi identificado que existem estudos que utilizam esse modelo combinado à rede bayesiana, para encontrar as probabilidades de ocorrência das consequências em um cenário de acidente específico, considerando condições variadas. Como exemplo, no estudo de Wu *et al.* (2016) é adicionar o processo de degradação dos componentes na análise para estruturar um modelo preditivo para acidentes em processo de perfuração de poço com sistema *Manage Pressure Drilling* (MPD). Enquanto o estudo de Kanes *et al.* (2017) utiliza uma análise de risco dinâmica, ao associar dados de evidências com variáveis contínuas e discretas para acompanhar em tempo real os potenciais aumentos dos níveis de risco em um cenário de queima de bobinas no ambiente *offshore*. No artigo de Ahmed *et al.* (2019) e na pesquisa de Squillante Jr. *et al.* (2018) foram

aplicados modelos de *bowtie*, considerando o algoritmo de MICE (Imputação Multivariada por Equações Encadeadas) e rede bayesiana para garantir a propriedade de um diagnóstico de segurança em meio a um cenário de falta de dados relativo a um acidente ocorrido em uma refinaria no Texas. A pesquisa de Wang *et al.* (2021) propôs uma modelagem de análise de probabilidade de falha dinâmica para monitoramento do risco de uma rede de linhas de gás, através da conversão do *bowtie* em uma rede bayesiana, utilizando o modelo de covariância para atualização das probabilidades de falha. E o estudo de Yunana *et al.* (2021) desenvolveu um modelo de análise de risco usando a conversão do *bowtie* em rede bayesiana para combinar dados empíricos observados e opinião de especialistas para avaliar a proliferação da bactéria *Legionella* e da exposição humana em águas subterrâneas.

Portanto, é possível observar nesses estudos que a conversão do modelo de *bowtie* para rede bayesiana está associada às vantagens de avaliar eventos com variados estados, uso de opinião de especialistas e cenários de risco, considerando as causas e as consequências de um ambiente perigoso. Além disso, a maioria desses estudos realizou uma avaliação dinâmica para o cenário. Essas vantagens presentes no uso da rede bayesiana são as mesmas limitações existentes nas técnicas da árvore de falha e de evento presentes na modelagem de *bowtie*. Sendo assim, a rede bayesiana é uma alternativa de técnica possível de ser aplicada em casos em que as técnicas de árvore de falha e de evento não são apropriadas. Portanto, a partir da pesquisa bibliográfica, foi percebido que a rede bayesiana é um método de vasta aplicação para estudar a probabilidade de ocorrência de um acidente para casos de uso de opinião de especialistas e com componentes/elementos com variados estados, a fim de buscar o gerenciamento de risco para manter a segurança operacional de um sistema.

A rede bayesiana é um método que busca quantificar a confiabilidade de um sistema ou evento a partir da probabilidade de falha dos seus eventos básicos, por meio de grafos acíclicos. Ela é aplicável em várias áreas, como exemplo, nos estudos de Mahadevan, Zhang e Smith (2001), para estruturas mecânicas e civis; no artigo de Gran e Helminen (2001) e Celeux, Corset e Lannoy (2006), em usinas nucleares; em sistemas de energia apresentados em Yongli *et al.* (2008); e na área *offshore*, com o trabalho de Droguett *et al.* (2006). Esse método foi sendo vastamente aplicado com o passar dos anos em diferentes condições de cenários, como apresentado no estudo de Neil e Marquez (2012), em que foi criado um modelo bayesiano híbrido para modelar a confiabilidade em sistemas reparáveis com componentes degradados e utilizando dados

de opinião de especialistas por meio da simulação de Monte Carlo e algoritmo de inferência, sendo, assim, possível visualizar o passo a passo do cálculo de disponibilidade de um sistema, considerando ou não um plano de manutenção. Os estudos realizados por Cai *et al.* (2012a; 2012b; 2012c; 2014) e Liu *et al.* (2015a) aplicaram a rede bayesiana para o cenário de acidente chamado *blowout*, considerando o equipamento de *blowout preventer* (BOP) e usaram múltiplos estados de falha, causa de falha comum e várias fontes de informação para coleta de dados. Esses trabalhos criaram uma estrutura lógica para realizar os estudos de confiabilidade de um sistema para cenários em que os componentes possuem estados degradados, assim como em situações em que a falha de um subsistema pode gerar falhas em vários componentes distintos e utilizar a combinação de dados não homogêneos para estimar a confiabilidade do sistema, respectivamente. Além dessas variadas condições, a rede bayesiana também pode ser aplicada em casos de confiabilidade humana, em que há a consideração em analisar as causas e efeitos provocados por erros humanos em sistemas operacionais, como apresentado nos estudos de Podofillini e Dang (2013) e Mkrtchyan, Podofillini e Dang (2015), que conseguiram incluir à tabela de probabilidade condicional os erros humanos e, assim, agregar ao julgamento de especialistas na probabilidade de erros humanos. Assim como nos estudos de Cai *et al.* (2013b), Baraldi *et al.* (2015) e Musharraf *et al.* (2016), que incluíram o fator humano como influenciador da probabilidade de falha do sistema de operações *offshore* para um evento de *blowout*. Esses estudos apresentaram modelos para aplicação em casos de modelagem de confiabilidade pela inclusão do fator humano na rede bayesiana.

Além disso, foi identificado que a rede bayesiana poderia ser aplicada em conjunto com outros modelos, ampliando a sua possibilidade de execução em cenários distintos. Como exemplo, combinada ao método de FMEA, apresentado em Wang *et al.* (2005), para obter índices probabilísticos de indisponibilidade; criando um modelo de análise de confiabilidade que reduz a necessidade computacional avançada; com o *bowtie*, em Abimbola *et al.* (2015) e Khakzad, Khan e Amyotte (2013a), que combinaram esses modelos para propagar a incerteza dos dados e adicionaram os componentes com estados degradados, respectivamente, para calcular a confiabilidade dos eventos e a probabilidade de ocorrência das consequências. Outra técnica possível é a combinação com rede de Petri, como apresentado por Andrews e Fecarotti (2017), que demonstraram o efeito que o *design* e as opções de manutenção têm no desempenho do sistema, criando um modelo genérico para otimização de processos com planos de

manutenção. E também com a técnica de árvore de evento, como nos trabalhos de Bearfield e Marsh (2005) e Li, Tao e Jia (2015), em que apresentaram um modelo de como usar a probabilidade condicional para representar as consequências de uma árvore de evento.

Pela pesquisa bibliográfica, ainda foi percebido que a rede bayesiana também foi combinada com casos de inferência probabilística. Artigos, como o de Kelly e Smith (2009), utilizaram a simulação de Monte Carlo para o cálculo das distribuições conjuntas das variáveis selecionadas. Entretanto, com as limitações de tempo de execução e os requisitos de memória, algumas alternativas foram sendo criadas com rede bayesiana. O estudo de Cadini e Gioletta (2016) propôs um novo método, conhecido como Monte Carlo Bayesiano, para estimar pequenas probabilidades em cenários de risco. Entretanto, outros autores seguiram novos caminhos distanciados da computação, como Guan *et al.* (2012), que propuseram uma abordagem analítica para estimativa da confiabilidade, usando o método de *Laplace*, combinado com rede bayesiana.

Com a necessidade de uma análise dinâmica para o cálculo da probabilidade de falha de sistemas, a rede bayesiana dinâmica foi sendo aplicada em vários estudos, como o realizado por Duim (2017), e apresentados no Apêndice A. Nesse apêndice, consta toda a cronologia de pesquisa para o estado da arte, com o modelo de prisma e a revisão bibliográfica de rede bayesiana dinâmica, ao longo dos anos, em sua evolução. O Apêndice B contém o estado da técnica identificado para esta pesquisa.

Em alguns setores do mercado, os processos operacionais possuem uma complexidade associada à estruturação dos componentes, como exemplo, as redundâncias e os diagramas de bloco mistos, além da alta confiabilidade dos componentes, que provocam a redução de dados, com ocorrência de falhas dos componentes e do sistema, que geram uma escassez de informações. Para a análise de risco em meio a esse cenário, torna-se necessário realizar uma coleta de dados em distintas fontes não homogêneas, como a partir de dados observados em componentes semelhantes, ou em condições de operações diferentes, por meio da elicitación feita com a opinião de especialistas, entre outros. Esse processo de coleta introduz uma inevitável incerteza aos dados da amostra, conhecida como variabilidade populacional, sendo a população o conjunto de dados sobre o processo operacional analisado (KELLY; SMITH, 2011). Essa incerteza é propagada ao longo do tempo para a estimativa da probabilidade de ocorrência de falha para esses tipos de componentes. A ausência da

propagação pode gerar informações não realistas ao cenário estudado. Portanto, uma vantagem gerada pelo uso de dados de fontes variadas é ajudar na estimativa de parâmetros de confiabilidade, como a taxa de falha, para componentes com alta confiabilidade (WANG *et al.*, 2012). Uma alternativa para realizar essa estimativa de probabilidade é utilizar a modelagem bayesiana hierárquica, ao invés da estatística clássica, visto que os dados não são idênticos e igualmente distribuídos (iid).

Alguns estudos demonstraram a aplicação dessa modelagem hierárquica para estimar as probabilidades, como a pesquisa de Andrade e Teixeira (2015), que aplicaram essa modelagem para quantificar dois indicadores associados à degradação geométrica das vias ferroviárias de Lisboa, norteados pelas taxas de deterioração e qualidade dos parâmetros. A pesquisa de Liu *et al.* (2017) utilizou esse modelo hierárquico com hiperparâmetros com poucas informações prévias, combinando a modelagem Gibbs para a simulação e as curvas probabilísticas de ciclo de estresse para as distribuições preditivas, a fim de prever dados de fadiga, por meio de aleatoriedade dos parâmetros e considerando a dispersão das observações. O estudo de Duim (2017) apresentou uma combinação de rede bayesiana dinâmica e modelagem bayesiana hierárquica para calcular a probabilidade de ocorrência do acidente de *blowout*, dada a ocorrência de *kick*, considerando incerteza no fator de cobertura e opinião de especialistas. Mäkinen e Vanhatalo (2018) aplicaram o modelo bayesiano hierárquico para analisar a distribuição espaço-temporal dos mamíferos marinhos do Ártico, a partir de dados heterogêneos presentes em artigos científicos, com o objetivo de estimar quantitativamente os efeitos das covariáveis ambientais na distribuição desses mamíferos e analisar se suas distribuições mudaram com a mudança ambiental. Jafari, Brown e Gauchia (2019) propuseram usar a modelagem hierárquica combinada ao *Metroplis-Hasting* Monte Carlo, para estimar a perda de capacidade probabilisticamente da bateria do veículo elétrico, incorporando os aspectos de envelhecimento da bateria com dados de diferentes condições de uso. O estudo de Babaleye, Khorasanchi e Kurt (2018) utilizou a modelagem bayesiana hierárquica combinada à rede bayesiana, para estimar o risco para os processos de abandono e descomissionamento para os poços *offshore*, utilizando dados limitados do ciclo de vida do poço. E a pesquisa de Wang *et al.* (2022) buscou determinar os parâmetros do solo para a segurança da engenharia geotécnica marítima e, devido ao número limitado de amostras de furos disponíveis, o processo de estimativa envolveu grande incerteza, que foi propagada pela modelagem bayesiana hierárquica para prever a porosidade do solo.

Esses estudos demonstraram que não foi encontrado nenhum estudo que aplicou um *bowtie* dinâmico, considerando a rede bayesiana dinâmica e a modelagem bayesiana hierárquica para calcular a estimativa das probabilidades de ocorrência e a opinião de especialistas e dados de alto nível como fonte de dados para os eventos analisados. Com o intuito de compreender a lacuna a ser preenchida pela pesquisa, o Quadro 1 apresenta os artigos encontrados na literatura. Esse quadro contém as pesquisas e artigos que referenciam o uso da rede bayesiana com *bowtie* e com a modelagem bayesiana hierárquica para propagação de incerteza e base de dados de entrada. O quadro indica com um *check* (✓) quando o artigo utilizou a abordagem proposta na coluna em sua pesquisa. As colunas em negrito mostram as abordagens propostas na metodologia desta tese para indicar a lacuna da literatura.

Diante do exposto e considerando-se as características das redes bayesianas como abordagem para modelar as reações de dependência entre eventos e a modelagem bayesiana hierárquica ser uma estrutura flexível para a estimativa das probabilidades de ocorrência dos eventos de interesse, a presente tese pretende responder ao seguinte problema de pesquisa: Como estimar as métricas de confiabilidade e risco em uma estrutura de *bowtie* dinâmico, considerando-se diferentes fontes de informações e suas incertezas?

**Quadro 1:** Quadro resumo do estado da arte e lacuna da literatura encontrada

REFERÊNCIA	<u>Abordagem - Bowtie</u>				<u>Dados de Entrada</u>			<u>Propagação de Incerteza</u>		
	Estática	Dinâmica	Conversão rede Bayesiana	<b>Conversão rede Bayesiana dinâmica</b>	Dados Genéricos	Opinião de Especialistas	<b>Combinação de Opinião de Especialista e dados de alto nível</b>	Não Incluído	Incluído	Incluído por Modelagem Bayesiana Hierárquica
Ouache and Pennicott (2016)	✓			☒	✓		☒	✓		☒
Khakzard <i>et al.</i> (2013a)	✓		✓	☒	✓		☒	✓		☒
Ouache <i>et al.</i> , 2015	✓			☒	✓	✓	☒	✓		☒
Wu <i>et al.</i> (2016)		✓	✓	☒	✓	✓	☒		✓	☒
Kanes <i>et al.</i> (2017)		✓		☒	✓		☒	✓		☒
Squilante <i>et al.</i> (2018)	✓		✓	✓	✓	✓	☒		✓	☒

REFERÊNCIA	<u>Abordagem - Bowtie</u>				<u>Dados de Entrada</u>			<u>Propagação de Incerteza</u>		
	Estática	Dinâmica	Conversão rede Bayesiana	Conversão rede Bayesiana dinâmica	Dados Genéricos	Opinião de Especialistas	Combinação de Opinião de Especialista e dados de alto nível	Não Incluído	Incluído	Incluído por Modelagem Bayesiana Hierárquica
Babadeye <i>et al.</i> (2019)		✓	✓	☒	✓	✓	☒	✓		☒
Igras and Creed (2020)	✓			☒	✓		☒		✓	☒
Mohammadfam <i>et al.</i> (2020)	✓			☒	✓		☒	✓		☒
Wei <i>et al.</i> (2020)			✓	☒	✓		☒		✓	☒
Wang <i>et al.</i> (2021)		✓	✓	☒		✓	☒	✓		☒
Chen <i>et al.</i> (2021)		✓	✓	☒	✓		☒	✓		☒
Yunana <i>et al.</i> (2021)	✓		✓	☒	✓	✓	☒	✓		☒
De Barnier <i>et al.</i> (2022)		✓		☒	✓		☒		✓	☒
Soomro <i>et al.</i> (2022)	✓			☒	✓		☒	✓		☒
Wen and Kan (2023)	✓			☒	✓		☒	✓		☒
<b>LACUNA ENCONTRADA</b>				☒			☒			☒
<b>(DUIM <i>et al.</i>, 2023)</b>				✓			✓			✓

Fonte: A autora (2023)

### 1.3 OBJETIVO DA PESQUISA

O objetivo geral deste estudo consiste em estruturar uma modelagem dinâmica de risco a partir de um procedimento metodológico de *bowtie* dinâmico, combinando modelagem bayesiana hierárquica via rede bayesiana dinâmica para um cenário com informações não homogêneas sobre dados de falha dos eventos, ou seja, é considerado as incertezas associadas à variedade de fontes de dados.

A partir desse procedimento metodológico, foi possível atualizar as métricas de confiabilidade dos componentes/sistemas, considerando-se todos os níveis hierárquicos dos dados do sistema e suas respectivas incertezas.

Com a finalidade de alcançar o objetivo geral abordado, os seguintes objetivos específicos precisam ser atendidos:

- i. Modelar o *bowtie* para um cenário de risco;
- ii. Modelar um *bowtie* dinâmico via rede bayesiana dinâmica para o mesmo cenário;
- iii. Incluir a modelagem bayesiana hierárquica no modelo de *bowtie* dinâmico estruturado.

#### 1.4 CONTRIBUIÇÃO E ORIGINALIDADE DA PESQUISA

A originalidade do estudo foi encontrada a partir de uma busca detalhada em pesquisas acadêmicas e científicas publicadas até junho de 2023, em periódicos nacionais e internacionais e eventos científicos sobre *bowtie* e a técnica de confiabilidade de rede bayesiana, rede bayesiana dinâmica e modelagem bayesiana hierárquica, tendo em vista as suas vantagens apresentadas anteriormente, como a propagação de erro em meio a um cenário com poucos dados de falha existentes. Portanto, o ineditismo está associado à combinação da modelagem bayesiana hierárquica e o *bowtie* dinâmico, para estimativa das probabilidades de ocorrência de eventos de alto risco, com a finalidade de atualizá-las a partir de informações novas obtidas e programar melhores planos de ação e manutenção, a fim de evitar acidentes.

As pesquisas e estudos encontrados pela coleta bibliográfica realizaram o cálculo de confiabilidade por meio de rede bayesiana dinâmica, considerando um valor fixo para os parâmetros que representavam as distribuições de probabilidade definidos pela opinião de especialistas e dados genéricos existentes. Diferente deles, a proposta deste estudo consiste em utilizar os valores estimados pela opinião de especialistas e dos dados de falha de eventos/componentes semelhantes para estimar a probabilidade de falha dos componentes por meio da modelagem bayesiana hierárquica. Portanto, essa modelagem contém os valores de probabilidade dos eventos/componentes, seguindo uma distribuição de probabilidade, não apenas um número fixo, como as outras pesquisas. A vantagem é indicar um intervalo de probabilidade de ocorrência de falha que permite que seja possível construir um plano de manutenção mais realístico, pois é considerado esse intervalo de tempo para a possível ocorrência da falha.

A relevância desta proposta está em oferecer um modelo matemático com um sequenciamento de ações e procedimentos lógicos que possa ser aplicado a qualquer sistema operacional com poucas informações de falha a respeito dos componentes geradores do risco no processo e que tenha a possibilidade de causar um acidente.

Portanto, esta pesquisa contribui favoravelmente para o mercado, vista a sua aplicabilidade em qualquer setor que tem a finalidade de estudar os riscos de operação qualitativa e quantitativamente, com o objetivo de prevenir acidentes e sustentar as decisões referentes a cenários com poucos dados. O ganho científico gerado para a academia está em preencher a lacuna da literatura e estruturar um modelo que auxilia no cálculo da probabilidade de ocorrência de acidente, considerando o cenário de dados escassos e dinamicidade do processo operacional.

Além disso, esta produção científica coopera para a sociedade, pois oferece aos profissionais envolvidos no estudo do risco informações que colaboram com a tomada de decisão organizacional. Essas decisões podem ser vinculadas a ações de manutenção, execução das atividades operacionais e intervenções nos procedimentos de segurança. Isso contribui para a segurança no ambiente de trabalho, assim como com a redução dos riscos relacionados ao meio ambiente envolvido, além da redução de custo com ações de manutenção desnecessárias.

## 1.5 ASPECTOS DA INTERDISCIPLINARIDADE DA PESQUISA

A interdisciplinaridade busca romper as fronteiras disciplinares por meio da intercomunicação, a fim de gerar uma renovação no domínio metodológico produzido pela disciplinaridade (JACOBS; FRICKEL, 2009). Portanto, o conhecimento produzido a partir da troca de experiência, pontos de vista e ideias de cada indivíduo, em cada setor do mercado, gera uma sabedoria para a solução de um problema complexo em sua totalidade.

Para alcançar esse âmbito da interdisciplinaridade, esta pesquisa, no que se refere ao conteúdo, interage com as áreas disciplinares de matemática e estatística, engenharia de petróleo, engenharia elétrica, nuclear, química, entre outras. Por meio dessas áreas, são geradas informações a serem utilizadas na formulação metodológica proposta na pesquisa, como: inferência bayesiana, rede bayesiana dinâmica, árvore de evento; além das relacionadas ao caso estudado, como estudo de segurança de poço e incidentes/acidentes em plataformas de petróleo. Portanto, o procedimento de construção da originalidade desta tese segue os princípios da interdisciplinaridade, por tentar conectar os conteúdos referentes às diversas áreas e, assim, montar uma estrutura que colabore com a tomada de decisão referente a um problema.

Outro âmbito associado à interdisciplinaridade é referente ao método. A técnica de rede bayesiana dinâmica usada neste estudo foi inicialmente enfatizada no campo da medicina e depois disseminada em outros setores. Sendo assim, é possível concluir que essa técnica pode ser aplicada em várias áreas e não está enraizada em uma única disciplina, por conseguinte, pode ser caracterizada como interdisciplinar.

Para a construção do conhecimento da tese, foi necessário que ocorresse um diálogo entre especialistas de várias áreas, assim como a leitura de vários artigos em setores diversos. Foi preciso realizar uma interação entre profissionais de áreas distintas para construir a aplicação deste estudo e validar a proposta do *framework* metodológico apresentado. Para o caso de aplicação no setor de óleo e gás, foram reunidos profissionais que estavam associados ao evento indesejado, como geólogos, engenheiros e biólogos, que permitiram a formulação de ideias para estruturação do problema comum vivenciado (evento indesejado). Por causa dessa interação, a percepção de cada especialista gerou uma resposta que permitiu construir a lógica da situação problema para todos os pontos de vista, sendo essa a característica requerida por uma pesquisa interdisciplinar.

Além disso, como o intuito desta tese está em construir um procedimento para atualização de métricas de confiabilidade que possa ser aplicado em qualquer setor, dependendo do objetivo da pesquisa, a metodologia também se caracteriza como interdisciplinar. Isso porque o procedimento não é fixado para uma única área, assim como há a necessidade de interação entre várias disciplinas para a construção do ambiente/evento de interesse.

Em vista disso, esta pesquisa se caracteriza como um estudo interdisciplinar, por conseguir interagir e dialogar com várias áreas de conhecimento, no que se refere ao conteúdo, ao método aplicado e à formação dos profissionais envolvidos.

## 1.6 ESTRUTURA DA PESQUISA

Esta tese é estruturada em seis capítulos, a fim de facilitar a compreensão do tema abordado. O capítulo 1 consiste em apresentar uma introdução do tema a ser desenvolvido no trabalho, com a abordagem dos objetivos, da situação problema e do interesse do autor em discursar sobre ele. Apresenta ainda a revisão bibliográfica, contendo a varredura cronológica dos temas associados à tese que servem de sustentação para a originalidade da pesquisa.

O capítulo 2 contém uma fundamentação teórica que disserta assuntos relevantes para melhor entendimento da aplicabilidade do estudo, como rede bayesiana, rede bayesiana dinâmica, árvore de evento, inferência bayesiana e modelagem bayesiana hierárquica.

Na sequência, o capítulo 3 detalha a metodologia aplicada na pesquisa, abordando a estrutura do modelo e suas fases.

No capítulo 4, é apresentada uma fundamentação teórica referente à segurança de poços no setor de óleo e gás, focada no evento de quebra de *riser*, o qual foi aplicado na metodologia proposta.

O capítulo 5 apresenta o emprego da modelagem de *bowtie* dinâmico para o caso, com a discussão de resultados.

O capítulo 6 contém a conclusão e recomendações futuras da pesquisa.

## 2 FUNDAMENTAÇÃO TEÓRICA

A seção de fundamentação contém as informações, características e conceitos sobre técnicas utilizadas na metodologia de pesquisa e que serão combinadas para realização da avaliação dos riscos de um evento indesejado. Sendo assim, os temas apresentados serão rede bayesiana, rede bayesiana dinâmica, árvore de evento dinâmica e modelagem bayesiana hierárquica. Para cada um deles, houve uma explicação do uso para melhor compreensão da aplicação, assim como seus princípios e ideias.

### 2.1 MODELAGEM DA CONFIABILIDADE VIA REDE BAYESIANA

#### 2.1.1 Contextualização

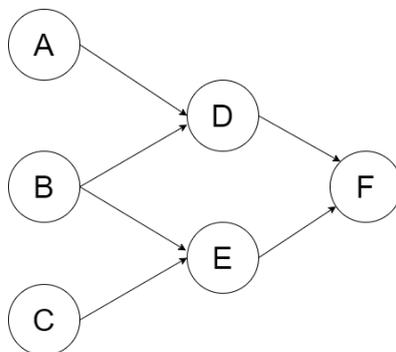
O cálculo da confiabilidade pode ser realizado a partir de técnicas de inferência estatística, considerando sistemas variados em suas condições operacionais (LEWIS, 1987). A partir das características dos componentes ou do processo associado ao evento estudado, é selecionado o método de análise de risco mais adequado para o cenário existente e do objetivo a ser alcançado. Alguns exemplos de métodos são: diagrama de bloco, rede de Petri, árvore de falha, cadeia de Markov. Outro método existente é a rede bayesiana (RB), que considera em seu cálculo a incerteza dos dados mediante a complexidade dos sistemas atuais (ARZAGHI *et al.*, 2018; CHANG *et al.*, 2019). A rede bayesiana é representada por meio de um grafo acíclico direcionado formado por nós (variáveis) e arcos (conexões) (LI *et al.*, 2018).

A modelagem via rede bayesiana é dividida em dois segmentos, o qualitativo e o quantitativo. O qualitativo representa a interpretação e a descrição do fenômeno por meio da rede de relacionamentos; e o quantitativo, a lógica matemática dele. O âmbito qualitativo é dado pelo grafo acíclico direcionado, com os nós retratando as variáveis do sistema e os arcos simbolizando a dependência ou relação causal entre os nós. Já o quantitativo é caracterizado pelas tabelas de probabilidades condicionais que representam as relações probabilísticas de dependência entre os nós existentes (TORRES-TOLEDANO; SUCAR, 1998). Um exemplo de estrutura da rede bayesiana está apresentado na Figura 1. Posteriormente, a parte quantitativa será abordada.

Em geral, existem três tipos de nós na rede bayesiana: (i) nó sem nenhum nó ligado a ele, chamado de nó raiz; (ii) nó sem um nó posterior, chamado nó final, e (iii) nó com conectores anteriormente e posteriormente, conhecido como nó intermediário (HOSSEINI; AL KHALED; SARDER, 2016). O nó gerador de outro nó é chamado de

nó pai, e o receptor do arco direcionado do nó pai é chamado de nó filho. Para exemplificar, na Figura 1 anterior, o nó D é o nó filho dos nós A e B, assim como o nó D e E são nós pais do nó F.

**Figura 1:** Estrutura de uma rede bayesiana



**Fonte:** Autora (2023)

Após compreender a estrutura básica que compõe a rede bayesiana, agora é preciso entender a modelagem quantitativa, isto é, a lógica de cálculo associada a ela.

### 2.1.2 Modelagem da Rede Bayesiana

A rede bayesiana tem a capacidade de realizar dois tipos de avaliações no estudo do sistema: uma análise preditiva e outra diagnóstica. A análise preditiva é o cálculo realizado a partir dos nós pais até a probabilidade dos nós filho. Contextualizando um exemplo, considerando que um nó pai seja um evento e um nó filho um acidente, tem-se que a probabilidade condicional  $P(\text{acidente}|\text{evento})$  é calculada pela ocorrência de um acidente, dado que um evento ocorreu primeiro. Sua probabilidade é definida a partir da probabilidade de ocorrência de qualquer nó raiz. Isto é, o cálculo de probabilidade dos nós intermediários e dos nós finais depende das probabilidades marginais dos nós raízes e das probabilidades condicionais dos nós intermediários. Entretanto, uma na análise diagnóstica consiste na probabilidade definida como  $P(\text{evento}/\text{acidente})$ , em que a probabilidade de um evento ocorrer depende do acidente que ocorreu. Essa análise estuda as evidências existentes, e as informações calculadas na análise preditiva atualizam as probabilidades dos nós anteriores por meio de inferência. Portanto, essa análise permite realizar a atualização dos nós condicionalmente dependentes. Por conseguinte, a probabilidade *a posteriori* é definida pelas evidências observadas que atualizam as probabilidades do conjunto de variáveis (CAI *et al.*, 2013b; KHAKZAD;

KHAN; AMYOTTE, 2011; BOBBIO *et al.*, 2001). Essas abordagens de análise são feitas a partir da dependência entre as variáveis estudadas.

O teorema de Bayes é a equação que rege a lógica de construção da rede bayesiana, tendo em vista a condição de dependência entre as variáveis estudadas (MURPHY, 2002). Essa equação pode ser escrita por:

$$P(\theta|\alpha) = \frac{P(\alpha|\theta)*P(\theta)}{P(\alpha)} \quad (1)$$

Onde  $P(\theta)$  é a probabilidade *a priori* de uma variável ou um conjunto de variáveis,  $P(\alpha)$  é a probabilidade de dados observados ou evidências e  $P(\alpha|\theta)$  é a probabilidade condicional de uma variável  $\alpha$  dado um  $\theta$ , chamada também de função de verossimilhança. A probabilidade  $P(\theta|\alpha)$  é conhecida como a probabilidade *a posteriori*. Ela contém o grau de certeza baseado nos dados observados  $\alpha$ . Portanto, *a posteriori* pode ser obtida pela equação de atualização a partir das evidências existentes como:

$$P(\theta|\alpha) \propto P(\alpha|\theta) * P(\theta) \quad (2)$$

A dependência entre as variáveis de uma rede bayesiana pode ser medida pela distribuição de probabilidade condicional. Considerando a rede com  $n$  variáveis aleatórias  $x_1, x_2, \dots, x_n$ , a expressão geral para a distribuição de probabilidade conjunta pode ser escrita, segundo Hosseini, Al Khaled e Sarder (2016), como:

$$P(x_1, x_2, \dots, x_n) = P(x_1|x_2, \dots, x_n) * P(x_2|x_3, \dots, x_n) \dots P(x_{n-1}|x_n) * P(x_n) \quad (3)$$

Podendo ser simplificada para:

$$P(x_1, x_2, \dots, x_n) = \prod_{i=1}^n P(x_i|x_{i+1}, \dots, x_n) \quad (4)$$

A distribuição de probabilidade conjunta de uma rede bayesiana pode ser simplificada baseando-se no conhecimento dos nós pais de cada nó. Então, para o exemplo da Figura 1, como o nó F possui dois nós pais, D e E, então uma parte da distribuição de probabilidade conjunta, como a  $P(x_1|x_2, \dots, x_n)$  presente na equação 4,

pode ser escrita como  $P(x_F|x_D, x_E)$ . Considerando o conhecimento dessa propriedade, uma rede com  $n$  variáveis aleatórias  $x_1, x_2, \dots, x_n$ , em que o nó  $j$  ( $1 \leq j \leq n$ ) é associado a uma variável  $x_j$ , o grafo acíclico é a rede bayesiana representada pelas variáveis  $x_1, x_2, \dots, x_n$  que segue a seguinte equação para a distribuição de probabilidade conjunta (ADUMENE *et al.*, 2021; BHARDWAJ; TEIXEIRA; SOARES, 2022):

$$P(x_1, x_2, \dots, x_n) = \prod_{j=1}^n P(x_j | \text{Pais}(x_j)) \quad (5)$$

Em que  $\text{Pais}(x_j)$  denota o conjunto de todos os nós pais das variáveis  $x_i$  e um arco conectando o nó  $i$  ao nó  $j$  no grafo.

Utilizando a Figura 1 como exemplo, a equação da probabilidade conjunta pode ser, então, escrita como:

$$P(x_A, x_B, x_C, x_D, x_E, x_F) = P(x_A)P(x_B)P(x_C) P(x_D|x_A, x_B) P(x_E|x_B, x_C)P(x_F|x_D, x_E) \quad (6)$$

Sendo assim, a distribuição de probabilidade conjunta da rede bayesiana pode ser obtida a partir do produto de todas as probabilidades condicionais, usando a regra da cadeia, considerando independência entre as variáveis (PEARL, 1988).

A avaliação da confiabilidade por essa técnica é executada de forma preditiva, ou seja, a probabilidade de ocorrência do nó, que representa o objeto avaliado, é calculada com base nas probabilidades anteriores relacionadas aos primeiros nós, ou conhecidos como nós raízes, e à dependência condicional entre eles (CAI *et al.*, 2019). Por conseguinte, o cálculo da confiabilidade de um componente ou um sistema pela técnica da rede bayesiana depende da relação causal entre os nós estudados.

A representação quantitativa da rede bayesiana é construída a partir do teorema de Bayes, calculado para cada nó em seus estados de funcionamento. Para cada nó é associada uma probabilidade, que é definida *a priori* para um nó raiz e é calculada por inferência para os outros nós. O cálculo é baseado nas probabilidades dos nós pais e na tabela de probabilidade condicional (TPC). Considerando dois nós, A e B, sendo A o nó pai (nó raiz) e B o nó filho, e dois estados possíveis para cada nó, E1 e E2, a probabilidade *a priori* de A será a probabilidade de ela estar no estado E1 somado a estar no estado E2. Como o nó B é o nó filho, a TPC é associada a ele. Essa tabela

define a probabilidade condicional  $P(B|A)$ , a probabilidade do nó B dado o nó A. Ela é definida pela probabilidade de cada estado de B dados os estados de A. O raciocínio é semelhante quando avaliada a probabilidade  $P(A|B)$ , só que nesse caso o nó B é considerado para identificar a probabilidade do nó A. Todos os possíveis estados de análise constam na Tabela 1.

**Tabela 1:** Probabilidades de cada nó dependendo do estado

Nós	Estados	Probabilidades	
A	$S_{E1}$	$P(A = S_{E1}   B = S_{E1})$	$P(A = S_{E1}   B = S_{E2})$
	$S_{E2}$	$P(A = S_{E2}   B = S_{E1})$	$P(A = S_{E2}   B = S_{E2})$
B	$S_{E1}$	$P(B = S_{E1}   A = S_{E1})$	$P(B = S_{E1}   A = S_{E2})$
	$S_{E2}$	$P(B = S_{E2}   A = S_{E1})$	$P(B = S_{E2}   A = S_{E2})$

**Fonte:** Murphy e Russell (2002)

Portanto, a inferência da rede bayesiana para a identificação da distribuição marginal do nó B, definido por  $P(B = E1_B)$ , seguindo a lógica do teorema de Bayes, é dada pela equação 7. Ela contém as probabilidades de o nó B estar no estado E1, dado que o nó A está no estado E1 e no estado E2.

$$P(B = E1_B) = P(B = E1_B | A = E1_A) \cdot P(A = E1_A) + P(B = E1_B | A = E2_A) \cdot P(A = E2_A) \quad (7)$$

A forma de representar a tabela de probabilidade condicional para o exemplo da Figura 1 para o nó F, considerando que os estados de cada nó são E1 e E2, está apresentada na Tabela 2. Nela estão indicadas as possíveis combinações dos estados dos nós pais para gerar os estados do nó criança.

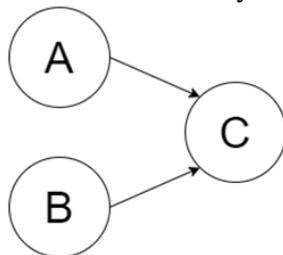
**Tabela 2:** Tabela de probabilidade condicional do nó F

		Nó F	
Nó D	Nó E	$F_{E1}$	$F_{E2}$
$D_{E1}$	$E_{E1}$	$P(F = F_{E1}   D = D_{E1}, E = E_{E1})$	$P(F = F_{E2}   D = D_{E1}, E = E_{E1})$
$D_{E1}$	$E_{E2}$	$P(F = F_{E1}   D = D_{E1}, E = E_{E2})$	$P(F = F_{E2}   D = D_{E1}, E = E_{E2})$
$D_{E2}$	$E_{E1}$	$P(F = F_{E1}   D = D_{E2}, E = E_{E1})$	$P(F = F_{E2}   D = D_{E2}, E = E_{E1})$
$D_{E2}$	$E_{E2}$	$P(F = F_{E1}   D = D_{E2}, E = E_{E2})$	$P(F = F_{E2}   D = D_{E2}, E = E_{E2})$

**Fonte:** A autora (2023)

A rede bayesiana pode ser construída seguindo quatro passos: a estruturação da rede, a modelagem do parâmetro, a inferência bayesiana e a verificação e validação da rede. A primeira etapa consiste em construir a rede, estruturando o grafo acíclico, que corresponde à parte qualitativa do processo, determinando os nós e especificando as ligações com os arcos. No segundo momento, a modelagem dos parâmetros da rede inclui atribuir as probabilidades das variáveis antes de qualquer evidência e especificar a probabilidade condicional, que se refere à probabilidade *a priori*. Para essas probabilidades, pode-se considerar variáveis discretas ou contínuas e, portanto, produzindo uma probabilidade *a posteriori* discreta ou uma distribuição de probabilidade, respectivamente. A modelagem utilizada para o parâmetro pode ser obtida por meio de elicitación de especialistas, de evidências passadas ou por mapeamento do processo. No terceiro passo, com a inferência bayesiana, as probabilidades da rede são atualizadas a partir das observações ou informações adicionadas ao processo. Para esse caso, usam-se alguns *softwares*, como o Netica, *software* R, Python, Hugin, entre outros. Por fim, as últimas etapas são a validação e a verificação do modelo. O processo de verificação é avaliado se o modelo representa precisão em relação às especificações correspondentes e pode ser feito por meio de análise de sensibilidade dos resultados obtidos. E a validação é caracterizada por determinar se o modelo reflete a realidade e pode ser posto como produtor de dados reais (CAI *et al.*, 2019).

Para exemplificação, uma rede bayesiana representada pela Figura 2 possui 2 nós raízes, nó A e B, e um nó filho, nó C. Nessa aplicação, é estudado o caso de uma pessoa que está atrasada para o trabalho. As causas desse atraso estão associadas ao indivíduo ter dormido até mais tarde ou ter ocorrido algum problema com o metrô, que é o meio de transporte utilizado. Pelo conhecimento adquirido, sabe-se que a probabilidade de o metrô parar de funcionar é de 30% e, como a pessoa analisada é muito pontual, a probabilidade de que tenha dormido até tarde é de 5%. Assim, o nó A é a causa gerada pelo “atraso por ter dormido até mais tarde”, B é o “atraso devido ao problema com o metrô” e o nó C é o evento da “a pessoa se atrasar”. Cada nó possui dois estados possíveis, o estado de verdadeiro e o de falso, que correspondem a ter ocorrido o atraso por essas circunstâncias ou não, respectivamente.

**Figura 2:** Estrutura de uma rede bayesiana de exemplo

**Fonte:** Duim *et al* (2017)

A expressão matemática da distribuição marginal para o nó C ser:

$$P(C) = P(A)P(B)P(C|A, B) \quad (8)$$

A probabilidade de o evento C acontecer depende do conhecimento sobre os estados das variáveis A e B e a probabilidade de C, presumindo que cada nó tem dois estados. Para cada nó da rede, é necessário identificar a probabilidade condicional. Para cada uma das combinações dos estados dos nós deve-se estimar a probabilidade de cada uma das combinações ser verdadeira. As probabilidades condicionais dos nós raízes, A e B, estão contidas na Tabela 3. A probabilidade condicional do nó C é dada pela Tabela 4.

**Tabela 3:** Probabilidades de cada nó raiz dependendo do estado

	Verdadeiro	Falso
P(A)	0,05	0,95
P(B)	0,30	0,70

**Fonte:** Neil *et al.*, 1996

**Tabela 4:** Probabilidade condicional do nó C

P(C   A,B)	B = Verdadeiro	B = Falso
A = Verdadeiro	(0,9 ; 0,1)	(0,7 ; 0,3)
A = Falso	(0,6 ; 0,4)	(0,1 ; 0,9)

**Fonte:** Neil *et al.*, 1996

Com essas informações é possível calcular a probabilidade do nó B ser verdadeiro, isto é, que houve um problema no metrô dado que o atraso ocorreu (Nó C). Pode-se fazer isso usando o teorema de Bayes:

$$\begin{aligned}
 &P(B = Verdadeiro | C = Verdadeiro) \\
 &= \frac{P(C = Verdadeiro | B = Verdadeiro) P(B = Verdadeiro)}{P(C = Verdadeiro)} \quad (9)
 \end{aligned}$$

Com essas informações, é possível calcular a probabilidade de o nó B ser verdadeiro, isto é, que houve um problema no metrô, dado que o atraso ocorreu (Nó C). Pode-se fazer isso usando o teorema de Bayes:

$$\begin{aligned}
 P(C = Verdadeiro) &= P(A = Verd.)P(B = Verd.)P(C = Verd. | A = Verd, B = Verd) \\
 &+ P(A = Verd.)P(B = Fals.)P(C = Verd. | A = Verd, B = Fals.) \\
 &+ P(A = Fals.)P(B = Verd.)P(C = Verd. | A = Fals., B = Verd) \\
 &+ P(A = Fals.)P(B = Fals.)P(C = Verd. | A = Fals, B = Fals) \\
 &= 0,05 * 0,3 * 0,9 + 0,05 * 0,7 * 0,7 + 0,95 * 0,3 * 0,6 + 0,95 * 0,7 \\
 &* 0,1 = 0,2755
 \end{aligned}
 \tag{10}$$

O próximo passo é calcular a função de verossimilhança  $P(C = Verdadeiro | B = Verdadeiro)$ , da seguinte maneira:

$$\begin{aligned}
 P(C = Verd. | B = Verd.) &= P(C = Verd. | A = Verd, B = Verd.)P(A = Verd.) + P(C = Verd. | A = Fals., B = Verd.)P(A = Fals.) \\
 &= 0,9 * 0,05 + 0,6 * 0,95 = 0,615
 \end{aligned}
 \tag{11}$$

E com isso, pode-se calcular a  $P(B = Verdadeiro | C = Verdadeiro)$ , dado na equação 11 anterior

$$\begin{aligned}
 P(B = Verdadeiro | C = Verdadeiro) &= \frac{P(C = Verdadeiro | B = Verdadeiro) P(B = Verdadeiro)}{P(C = Verdadeiro)} \\
 P(B = Verdadeiro | C = Verdadeiro) &= \frac{0,615 * 0,3}{0,2755} = 0,6697
 \end{aligned}
 \tag{12}$$

Após a análise, verificou-se que a probabilidade inicial de 0,3 por atraso por motivo de ter tido um problema no metrô foi para uma probabilidade de 0,67, mostrando um aumento, quando há dependência entre os eventos.

Por conseguinte, para o cálculo do diagnóstico da probabilidade, o mecanismo de inferência é realizado por meio da coleta e incorporação de novas informações (evidências). Esse processo é feito a partir do teorema de Bayes, em que a rede bayesiana atualiza as probabilidades dos eventos de acordo com os dados observados.

(WEBER *et al.*, 2012). Esse processo é caracterizado como a abordagem quantitativa da técnica bayesiana.

O estudo da rede bayesiana se baseia em conhecimento estatístico para obter o valor probabilístico de um parâmetro desconhecido e atualizá-lo a partir da utilização de probabilidade condicional. Sendo assim, a rede bayesiana proporciona mais flexibilidade nas aplicações de análises de risco, ao ser capaz de calcular a confiabilidade de um sistema, considerando a incerteza da fonte e dos dados de conhecimento (HECKERMAN; MAMDANI; WELLMAN, 1995). Segundo Cooper (1990), a vantagem dessa rede é a representatividade da relação consistente da probabilidade das variáveis dependentes. Ela pode ser utilizada para diagnóstico e interpretação de dados.

Entre os benefícios do uso da rede bayesiana estão: a representação gráfica das relações de dependência em sistemas complexos, facilitando a compreensão do problema; a capacidade de modelar quantitativamente as relações de dependência entre variáveis, com distribuição de probabilidade condicional, que permite a propagação da incerteza a partir de evidências existentes; e a capacidade de representar as variáveis em múltiplos estados. Além disso, as distribuições de probabilidade para as variáveis podem ser atualizadas com uma série de inferências, dadas as informações conhecidas sobre as variáveis, ou seja, as evidências (ZAGORECKI; DRUZDZEL, 2012).

A rede bayesiana permite mesclar conhecimentos de diversas naturezas, podendo ser dados de julgamento de especialistas (por meio de equações, regras lógicas ou probabilidades subjetivas), observação do comportamento do sistema (análise funcional e disfuncional) e dados de experiência de *feedbacks* (WEBER *et al.*, 2012). Devido a poucos dados de *feedback*, especialmente nos domínios da confiabilidade, análise de risco e manutenção, os trabalhos de pesquisa usam principalmente o julgamento de especialistas para construir a estrutura dos modelos (CELEUX; CORSET; LANNOY, 2006), sendo essa outra vantagem de seu uso.

A rede bayesiana é frequentemente considerada para modelar sistemas devido a sua habilidade de incorporar múltiplos problemas, interações e resultados e investigar *tradeoffs*. Além disso, ela está apta a utilizar dados e conhecimento de diferentes fontes e lidar com dados escassos, assim como propagar a incerteza das informações. Sua representação gráfica simples, que permite a construção sem habilidades técnicas específicas, é mais uma das vantagens do uso dessa técnica (CHEN; POLLINO, 2012).

As vantagens da rede bayesiana no cálculo da confiabilidade, considerando a incerteza e os múltiplos estados dos componentes, são características importantes que não são possíveis de serem utilizadas ao considerar uma modelagem via árvore de falha. Essa deficiência pode ser solucionada ao realizar a conversão da árvore de falha em rede bayesiana, sendo possível, assim, reproduzir as necessidades desejadas.

### 2.1.3 Conversão da Árvore de Falha em Rede Bayesiana

O trabalho realizado por Bobbio *et al.* (2001) sintetiza os passos para a realização a conversão de árvore de falha em rede bayesiana. São eles:

- (i) Para cada evento básico existente na árvore de falha (AF), é criado um nó raiz da rede bayesiana (RB). Para situações em que o evento básico é repetido na árvore, é preciso que ele seja inserido apenas uma vez na RB;
- (ii) Conecte os nós raízes na RB, relacionando com a devida correspondência aos nós intermediários, como apresentado na AF;
- (iii) Para cada portão lógico existente na AF, crie um correspondente na RB;
- (iv) Para cada portão lógico (AND, OR ou K:N) da AF, atribuir a equivalência na tabela de probabilidade condicional nos correspondentes nós da RB.

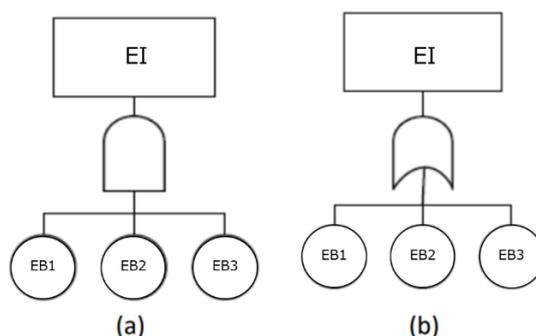
A árvore de falha e a relação de dependência entre os nós dados pelos arcos são representadas pelos portões lógicos. Os portões lógicos são as representações gráficas que ilustram as conexões entre os componentes e o sistema. Essa conexão entre os nós (variáveis) pelos arcos pode ser representada por lógicas de relacionamento, como série e paralelo, conhecidas também como portões lógicos OR e AND, respectivamente (STRAUB; DER KIUREGHIAN, 2010). Há outras lógicas possíveis, mas seguem o mesmo raciocínio dessas duas anteriormente comentadas. Sendo assim, as tabelas de probabilidade condicionais serão apresentadas de forma distinta para cada um desses relacionamentos.

Para exemplificação, na Figura 3, o portão AND significa que o Evento Intermediário (EI) ocorre caso, pelo menos, um dos eventos básicos (EB) ocorra. Enquanto o portão OR significa que o EI ocorre se todos os EBs ocorrerem (NUCLEAR REGULATORY COMMISSION, 1981). Esses portões estão apresentados pelas árvores de falha na Figura 3.

A Figura 4 representa dois portões, AND e OR, de uma árvore de falha para uma rede bayesiana com a apresentação da tabela de probabilidade condicional. Nela

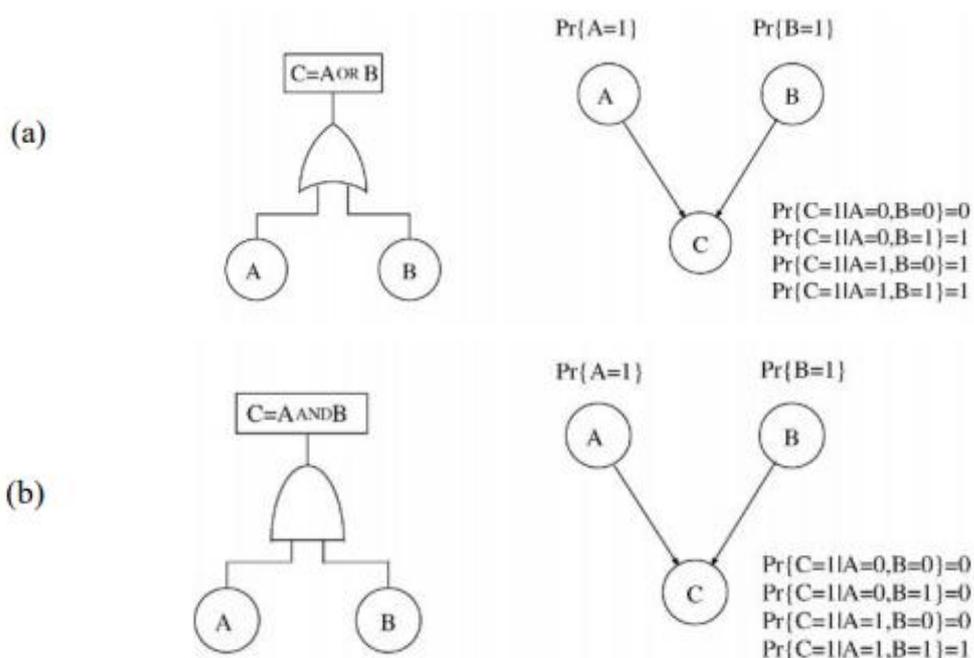
contém, em 4(a), uma AF com portão OR e, em 4(b), com portão AND. A Figura 4(a) indica que o evento C vai estar no estado de falha,  $C=1$ , quando o evento A ou o B estiver falho também, ou seja,  $C=1$  quando  $A=1$  ou  $B=1$ . Na Figura 4(b), com o portão lógica AND, o evento C vai estar falho quando ambos os eventos, A e B, estiverem falhos, isto é,  $A=1$  e  $B=1$ . Então, por exemplo, a probabilidade de o evento C estar falho, considerando que os eventos  $A=1$  (falho) e evento  $B=0$  (normal), é 0 (zero), pois sabe-se que o evento C vai estar no estado normal para a condição desse cenário. As probabilidades de o evento C estar no estado falho vai ser a soma de todos os possíveis estados de falha dos eventos A e B

**Figura 3:** Portões lógicos da árvore de falha (A) AND e (b) OR.



**Fonte:** Hamada *et al.* (2008)

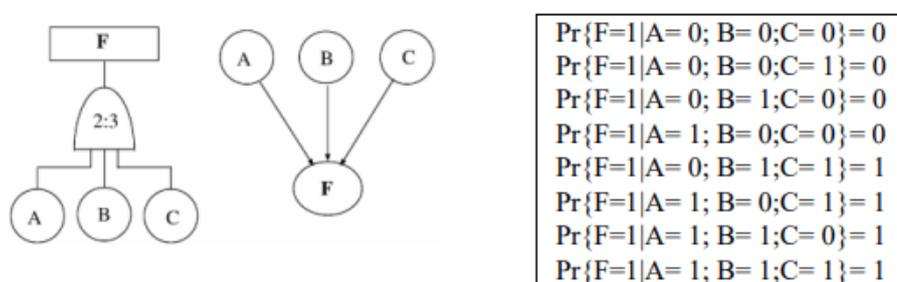
**Figura 4:** Conversão de AF em RB para os portões OR(a) e AND(b)



**Fonte:** Bobbio *et al.* (2001)

Para o caso de um portão lógico K:N, a conversão seguirá os mesmos passos, entretanto a tabela de probabilidade condicional será distinta das apresentadas pelos portões AND e OR. O portão K:N significa a relação de quantos eventos podem falhar em um conjunto total de eventos. Por exemplo, 3:4 significa que em 4 eventos (A,B,C,D) existentes, para que o sistema falhe, é necessário que 3 deles falhem. A Figura 5 apresenta a conversão de um caso 2:3. Ele significa que, para que o sistema falhe, é preciso que pelo menos dois portões venham a falhar. Sendo assim, a tabela de probabilidade será:

**Figura 5:** Conversão de AF em RB para o portão 2:3



**Fonte:** Bobbio *et al.* (2001)

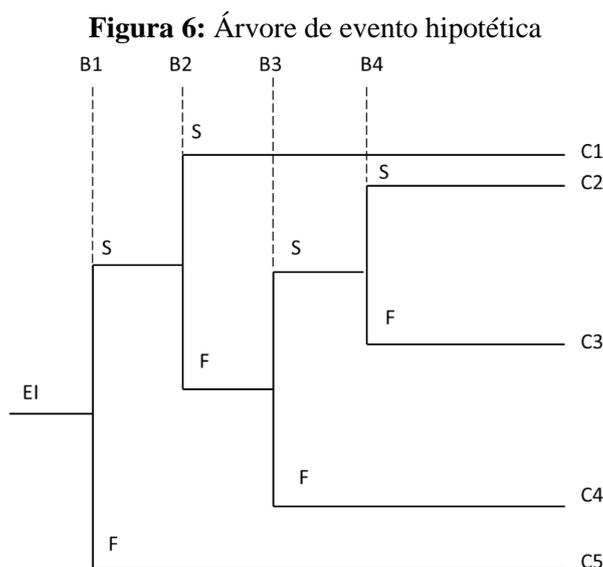
Portanto, dependendo das características e da função do sistema estudado, a modelagem via rede bayesiana pode melhor representar o cenário para o cálculo da confiabilidade do sistema e, assim, gerar resultados mais fiéis à realidade.

Com a necessidade de uma análise de risco ao longo do tempo, dada a dinamicidade dos sistemas e sua constante mudança, a rede bayesiana estática contém uma limitação de uso e, por isso, a rede bayesiana dinâmica se torna mais adequada nos processos atuais.

### 2.3 ÁRVORE DE EVENTO

A árvore de evento é uma representação gráfica com uma modelagem binária que tem por finalidade identificar e quantificar as possíveis consequências resultantes de um evento iniciador. Na análise de risco, o modelo de consequência e de resultados de um evento é sucessivamente usado em aplicações pré-acidentais, para examinar os precursores do acidente, e pós-acidentais; além de identificar os possíveis perigos (resultado dos eventos) para o evento acidental (AICHE, 2000).

A árvore de evento é uma ferramenta que tem por objetivo estudar as probabilidades de ocorrência de consequências a partir de um evento inicial. O acontecimento desse evento gera consequências que estão atreladas à evolução desse evento, devido à falha ou ao funcionamento de barreiras de segurança, isto é, caso uma dada situação ocorra, há possibilidades de as consequências serem impedidas, por meio de barreiras. Se a barreira falhar, outra barreira pode impedir o avanço do evento ou não. Esse processo acontece até a geração das consequências. Portanto, a evolução do sistema, seguida de uma ocorrência perigosa, é dividida em eventos discretos. Cada evento tem um finito conjunto de resultados, podendo ocorrer ou não (BEARFIELD; MARSH, 2005). Um exemplo de árvore de evento está contido na Figura 6, cujas siglas indicam: IE de “evento inicial”; “S” de sucesso, ou seja, a barreira de segurança funcionou; “F” de falha, isto é, a barreira falhou em sua execução, os “B’s” significam as barreiras de segurança e os “C’s” referem-se às consequências para cada um dos possíveis caminhos existentes.



**Fonte:** A autora (2023)

A técnica de sequenciamento de evento é uma representação indutiva e diagramática para avaliação de prováveis consequências a partir de um evento inicial. Sua estrutura é classificada em qualitativa e quantitativa. A análise qualitativa é a identificação dos eventos probabilísticos que são gerados pela propagação sequencial de um evento inicial até a estruturação das consequências ou resultados desse evento. Sua construção começa pela identificação do evento inicial desenhado à direita dos ramos da árvore que será montada. Cada ramo consiste em uma consequência do evento primário

e é conectado com o próximo ramo, que se refere a outro evento sequenciado, resultante do evento anterior. Cada um desses ramos estrutura um caminho para cada uma das consequências. Para cada uma delas há o interesse de se analisarem as probabilidades de ocorrência (MANNAN; LEES, 2005; NÝVLT; RAUSAND, 2012). Os caminhos são arquitetados a partir das barreiras de análise em cada situação existente. Por isso, a estruturação desse método é constituída por um evento inicial, as barreiras de segurança e as consequências geradas.

A análise quantitativa é estimação da probabilidade de ocorrência das consequências. Esse processo é dado pela multiplicação das probabilidades de ocorrências de todos os caminhos associados a essa consequência local desejada. Para o cálculo, é preciso a probabilidade de ocorrência do evento inicial disponível (HONG, E. *et al.*, 2009).

Em uma árvore de evento estática, o cálculo da probabilidade de ocorrência das consequências está relacionado às probabilidades do evento inicial e da falha ou não das barreiras. A fórmula lógica que se pode construir para a consequência  $C_2$  da Figura 12, por exemplo, é definida conforme apresentado abaixo, dado que o valor 1 indica que o evento aconteceu:

$$P(C1) = P(B1 = S|E1 = 1) * P(B2 = S|B1 = S) \quad (13)$$

Para os casos em que os caminhos produzem a mesma consequência, após a multiplicação das probabilidades, de acordo com o caminho, há a adição de cada conjunto que conduziu à mesma consequência.

Para essa árvore de evento, o evento inicial será denotado como EI e suas M barreiras de segurança (BS) de  $BS_i = 1, 2, \dots, M$ , cujos estados podem ser funcionando ou falho. A sequência que emerge de EI depende dos estados das BS, conduzindo a N possíveis consequências, que serão denotadas de  $C_1, C_2, \dots, C_N$ . Um dos casos de estudo é a probabilidade de uma consequência específica acontecer  $C_i$ , dado que o evento EI aconteceu. Segundo Xing, Zeng e Zio (2019), essa probabilidade condicional é representada por:

$$P_{C_i} = P\{C_i \text{ ocorrer} | EI \text{ ocorreu}\}, i = 1, 2, \dots, N \quad (14)$$



segunda adota uma amostragem Monte Carlo para geração de simulações (KLOOS; PESCHKE, 2006).

A análise de probabilidade de risco assume que a probabilidade de falha de uma barreira de segurança independe do tempo, e seus valores são estimados em dados estatísticos. Entretanto, na realidade, as barreiras de segurança são impactadas por processos de degradação, como vento, fadiga, fissuras, dentre outros, que provocam um aumento na probabilidade de falha do evento ao longo do tempo. Além disso, as condições existentes do meio e dos procedimentos operacionais do sistema mudam com o tempo e, com isso, podem ocasionar variações na probabilidade de falha das barreiras na mesma situação (ZHAO; GUO; WANG, 2018; DI MAIO; ANTONELLO; ZIO, 2018).

Assim como ocorre na árvore de falha, a árvore de evento possui as suas limitações com relação aos múltiplos estados e a não possibilidade de incerteza nos dados. Visto isso, a possibilidade de conversão da árvore de evento em rede bayesiana estática e dinâmica soluciona essa limitação e colabora para que a análise entre as causas e consequências possa ser realizada considerando essas condições. O mapeamento de um sequenciamento de evento para uma rede bayesiana pode ser baseado no estudo de Marsh e Bearfield (2007). Segundo esses autores, cada barreira de segurança do evento é representada por um nó com os estados de operação, como exemplo, com dois estados, sendo eles: falho ou sucesso de operação da barreira. As consequências geradas no sequenciamento de evento são representadas na rede bayesiana por um nó com tantos estados quanto número de consequências dela.

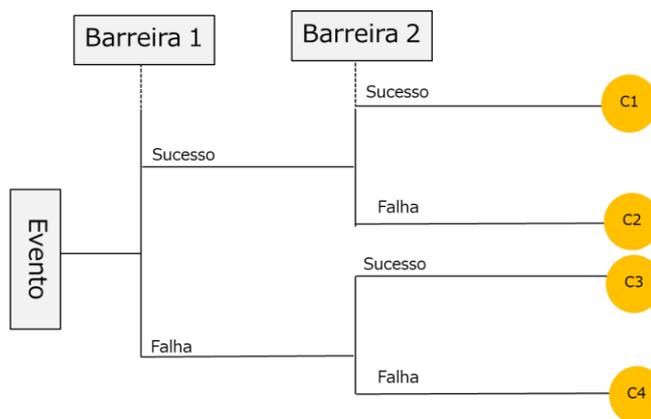
Portanto, cada barreira da árvore de evento é transformada para um nó da mesma composição com, pelo menos, dois estados (sucesso e falha), e as consequências são convertidas em um nó de consequências com múltiplos estados correspondentes ao número de consequências existentes na árvore de evento. A probabilidade de falha das barreiras de segurança é atribuída aos nós, agora modelados. A tabela de probabilidade condicional das consequências é modelada de acordo com as barreiras e o evento iniciador (BEARFIELD; MARSH, 2005; WU *et al.*, 2016).

Deve haver uma conexão entre cada nó da barreira de segurança com o nó das consequências somente se as probabilidades dos estados do nó das consequências são influenciadas pela probabilidade de falha ou sucesso dos nós das barreiras. As probabilidades dos nós das barreiras de segurança são definidas como probabilidades  $a$

*priori* e uma tabela de probabilidade condicional é atribuída ao nó da consequência (KHAKZAD; KHAN; AMYOTTE, 2013a).

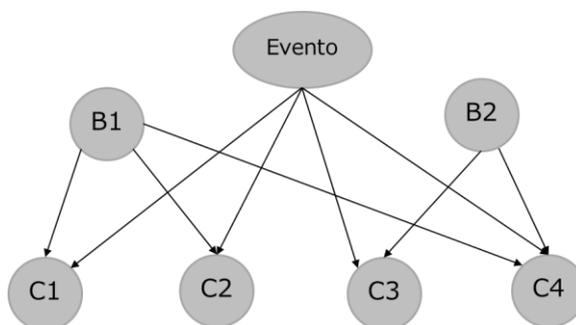
A Figura 8 apresenta um exemplo da árvore de evento e, na Figura 9, há a representação gráfica da conversão da árvore de evento para a rede bayesiana, em que, inicialmente, o evento, as barreiras e as consequências foram convertidas em nós da rede, e as conexões foram indicadas, concluindo a estruturação qualitativa.

**Figura 8:** Exemplo de árvore de evento



**Fonte:** A autora (2023)

**Figura 9:** Rede bayesiana construída pelo exemplo de árvore de evento



**Fonte:** A autora (2023)

Para a modelagem quantitativa, a tabela de probabilidade condicional precisa ser construída, contendo o evento iniciador, as barreiras e as consequências em cada condição dos estados das barreiras. A tabela de probabilidade condicional está apresentada na Tabela 5, com a estrutura lógica e a Tabela 6 com os resultados com os possíveis estados de cada barreira. O valor 1 indica que a consequência ocorreu para o cenário.

**Tabela 5:** Tabela de probabilidade condicional para a rede bayesiana da árvore de evento

Evento	Barreira 1	Barreira 2	Consequências				
			C <sub>0</sub>	C <sub>1</sub>	C <sub>2</sub>	C <sub>3</sub>	C <sub>4</sub>
$P(C = \text{Sucesso})$	$P(B1 = \text{Indiferente})$	$P(B2 = \text{Indiferente})$	$P(\text{Consequência} = C_0/C = \text{Indif., } B1 = \text{Indif., } B2 = \text{Indif.})$	$P(\text{Consequência} = C_1/C = \text{Indif., } B1 = \text{Indif., } B2 = \text{Indif.})$	$P(\text{Consequência} = C_2/C = \text{Indif., } B1 = \text{Indif., } B2 = \text{Indif.})$	$P(\text{Consequência} = C_3/C = \text{Indif., } B1 = \text{Indif., } B2 = \text{Indif.})$	$P(\text{Consequência} = C_4/C = \text{Indif., } B1 = \text{Indif., } B2 = \text{Indif.})$
$P(C = \text{Falha})$	$P(B1 = \text{Sucesso})$	$P(B2 = \text{Sucesso})$	$P(\text{Consequência} = C_0/C = \text{Falha, } B1 = \text{Sucesso, } B2 = \text{Sucesso})$	$P(\text{Consequência} = C_1/C = \text{Falha, } B1 = \text{Sucesso, } B2 = \text{Sucesso})$	$P(\text{Consequência} = C_2/C = \text{Falha, } B1 = \text{Sucesso, } B2 = \text{Sucesso})$	$P(\text{Consequência} = C_3/C = \text{Falha, } B1 = \text{Sucesso, } B2 = \text{Sucesso})$	$P(\text{Consequência} = C_4/C = \text{Falha, } B1 = \text{Sucesso, } B2 = \text{Sucesso})$
$P(C = \text{Falha})$	$P(B1 = \text{Sucesso})$	$P(B2 = \text{Falha})$	$P(\text{Consequência} = C_0/C = \text{Falha, } B1 = \text{Sucesso, } B2 = \text{Falha})$	$P(\text{Consequência} = C_1/C = \text{Falha, } B1 = \text{Sucesso, } B2 = \text{Falha})$	$P(\text{Consequência} = C_2/C = \text{Falha, } B1 = \text{Sucesso, } B2 = \text{Falha})$	$P(\text{Consequência} = C_3/C = \text{Falha, } B1 = \text{Sucesso, } B2 = \text{Falha})$	$P(\text{Consequência} = C_4/C = \text{Falha, } B1 = \text{Sucesso, } B2 = \text{Falha})$
$P(C = \text{Falha})$	$P(B1 = \text{Falha})$	$P(B2 = \text{Sucesso})$	$P(\text{Consequência} = C_0/C = \text{Falha, } B1 = \text{Falha, } B2 = \text{Sucesso})$	$P(\text{Consequência} = C_1/C = \text{Falha, } B1 = \text{Falha, } B2 = \text{Sucesso})$	$P(\text{Consequência} = C_2/C = \text{Falha, } B1 = \text{Falha, } B2 = \text{Sucesso})$	$P(\text{Consequência} = C_3/C = \text{Falha, } B1 = \text{Falha, } B2 = \text{Sucesso})$	$P(\text{Consequência} = C_4/C = \text{Falha, } B1 = \text{Falha, } B2 = \text{Sucesso})$
$P(C = \text{Falha})$	$P(B1 = \text{Falha})$	$P(B2 = \text{Falha})$	$P(\text{Consequência} = C_0/C = \text{Falha, } B1 = \text{Falha, } B2 = \text{Falha})$	$P(\text{Consequência} = C_1/C = \text{Falha, } B1 = \text{Falha, } B2 = \text{Falha})$	$P(\text{Consequência} = C_2/C = \text{Falha, } B1 = \text{Falha, } B2 = \text{Falha})$	$P(\text{Consequência} = C_3/C = \text{Falha, } B1 = \text{Falha, } B2 = \text{Falha})$	$P(\text{Consequência} = C_4/C = \text{Falha, } B1 = \text{Falha, } B2 = \text{Falha})$

Fonte: A autora (2023)

**Tabela 6:** Resultado da tabela de probabilidade condicional para a rede bayesiana da árvore de evento

Evento	Barreira 1	Barreira 2	Consequências				
			C <sub>0</sub>	C <sub>1</sub>	C <sub>2</sub>	C <sub>3</sub>	C <sub>4</sub>
Sucesso	Indiferente	Indiferente	1	0	0	0	0
Falha	Sucesso	Sucesso	0	1	0	0	0
Falha	Sucesso	Falha	0	0	1	0	0
Falha	Falha	Sucesso	0	0	0	1	0
Falha	Falha	Falha	0	0	0	0	1

Fonte: A autora (2023)

Para a estrutura dinâmica, o cálculo da transformação em uma rede bayesiana deve considerar o sucesso ou a falha da barreira de segurança ao longo do tempo. Ou seja, ao considerar um nó de segurança representado por  $SB_i$ , que é conectado anteriormente por um nó de segurança,  $SB_{i-1}$ , a probabilidade de falha de  $SB_i$  depende se  $SB_{i-1}$  está funcionando ou falhou. A estrutura lógica para esse caso é definida se  $SB_i$  deve ser conectado ao  $SB_{i-1}$  se e somente se  $P(SB_i|SB_{i-1}) \neq P(SB_i|SB_{i-1}^-)$ . A mesma lógica é aplicada ao nó de segurança  $SB_{i+1}$ , que deve também ser conectada ao nó  $SB_{i-1}$  se  $P(SB_{i+1}|SB_i, SB_{i-1}) \neq P(SB_{i+1}|SB_i, SB_{i-1}^-)$ . Sendo  $SB_{i-1}^-$  a probabilidade de falha do nó de segurança de  $SB_{i-1}$ . Outra conexão existente é entre os nós das barreiras e o nó que contém as consequências. Essa ligação deve acontecer se e somente se as probabilidades dos estados desse nó, ou seja, as consequências do evento forem

influenciadas pela probabilidade de falha ou sucesso dos nós de barreira de segurança (MARSH; BEARFIELD, 2007).

Após a estruturação da rede bayesiana dinâmica, é iniciada a construção das tabelas de probabilidades condicionais ao longo do tempo. As probabilidades das barreiras de segurança na árvore de evento serão definidas como as probabilidades *a priori* dos nós de segurança da rede bayesiana. A tabela de probabilidade condicional (TPC) é atribuída ao nó que contém as consequências, assim como aos nós intermediários de segurança. A TPC do nó que contém as consequências atua como portão lógico AND, e as TPCs atribuídas aos nós de segurança são representações de relações causais simples, diferente dos portões lógicos AND e OR, normalmente incorporados nas análises de risco por árvore de falha (HONG, E. *et al.*, 2009).

A árvore de evento está presente na estrutura do *bowtie*, que utiliza a mesma lógica de conversão. A transformação detalhada do *bowtie* é apresentada na seção seguinte, tanto para a árvore de evento quanto para a árvore de falha.

#### 2.4 CONVERSÃO DO *BOWTIE* EM REDE BAYESIANA

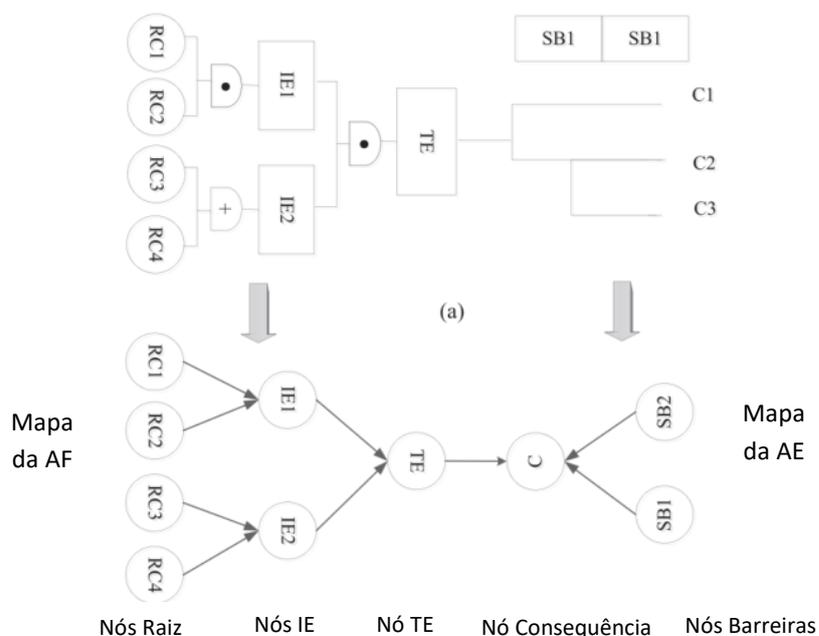
O modelo *bowtie* é uma abordagem gráfica com a finalidade de modelar um cenário de potencial acidente, em que são avaliados qualitativa e quantitativamente o evento iniciador e as consequências produzidas, sendo composto por uma árvore de falha e uma árvore de evento. A árvore de falha localiza-se à esquerda e a árvore de evento à direita, multiplicado pelo evento iniciador ou evento topo. A árvore de falha tem a finalidade de identificar as causas do evento topo, estruturada por uma lógica booleana. A árvore de evento identifica as potenciais consequências do evento topo que depende das barreiras de segurança e suas relações de falha e sucesso. Com esse modelo, é possível fazer uma análise sistemática com as combinações de ocorrência do evento iniciador, calculada pela árvore de falha, e como as falhas das barreiras associada ao evento topo podem gerar as consequências pela árvore de evento. A estrutura quantitativa é estruturada por vários métodos, como a simulação de Monte Carlo, caminho mínimo ou o método dos portões (LU *et al.*, 2015; KHAKZAD *et al.*, 2012; LI, CHEN and ZHOU, 2016).

O *bowtie* possui algumas limitações associadas à árvore de falha e à árvore de evento, como a não atualização das probabilidades *a priori* dos eventos básicos e adição de novas informações no tempo para uma avaliação do risco dinâmica. Para cobrir essa

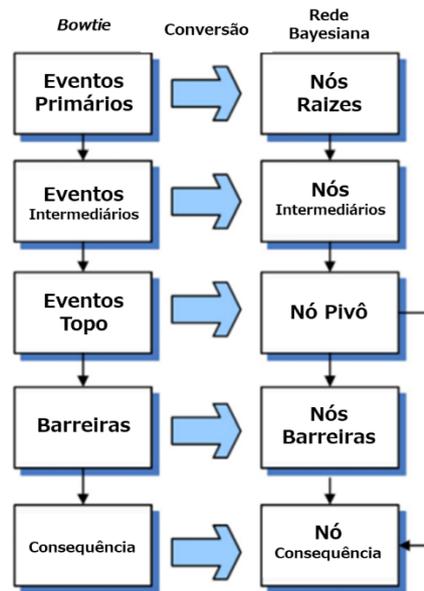
limitação estática, a rede bayesiana é utilizada para o mapeamento. A rede bayesiana é um modelo gráfico baseado em conhecimento com incerteza, estrutura e aprendizado de parâmetros (FAKHRAVAR *et al.*, 2017).

A conversão do *bowtie* em rede bayesiana é dividida em duas etapas, tendo em vista a presença da árvore de falha e da árvore de evento existentes em sua estrutura. Como apresentado anteriormente, tanto para a árvore de falha quanto para a árvore de evento, os eventos básicos presentes no evento iniciador, nas barreiras de segurança e as consequências são convertidos em nós da rede bayesiana. Cada barreira da árvore de evento é transformada para um nó da mesma composição, com pelo menos dois estados (sucesso e falha), e as consequências são convertidas em um nó de consequências com múltiplos estados correspondentes ao número de consequências existentes na árvore de evento. A probabilidade de falha das barreiras de segurança são atribuídas aos nós agora modelados. A Figura 10 demonstra como essa conversão qualitativa ocorre, e a Figura 11 apresenta uma representação lógica dessa conversão. A tabela de probabilidade condicional das consequências é modelada de acordo com as barreiras e o evento iniciador (BEARFIELD; MARSH, 2005; WU *et al.*, 2016), como apresentado anteriormente. Portanto, a conversão do *bowtie* para a rede bayesiana é dada pela combinação da transformação da árvore de falha e da árvore de evento.

**Figura 10:** Modelo de transformação do *bowtie* em rede bayesiana



**Fonte:** Wu *et al.* (2016)

**Figura 11:** Mapa de conversão da árvore de evento em rede bayesiana

**Fonte:** Khakzad *et al.* (2013<sup>a</sup>)

Junto a essa técnica de árvore de evento convertida em rede bayesiana, pode-se incorporar o modelo em que são consideradas múltiplas fontes de obtenção de dados, que permite o cálculo de probabilidade de ocorrência de um evento por inferência bayesiana. A esse modelo é dado o nome de modelo bayesiano hierárquico.

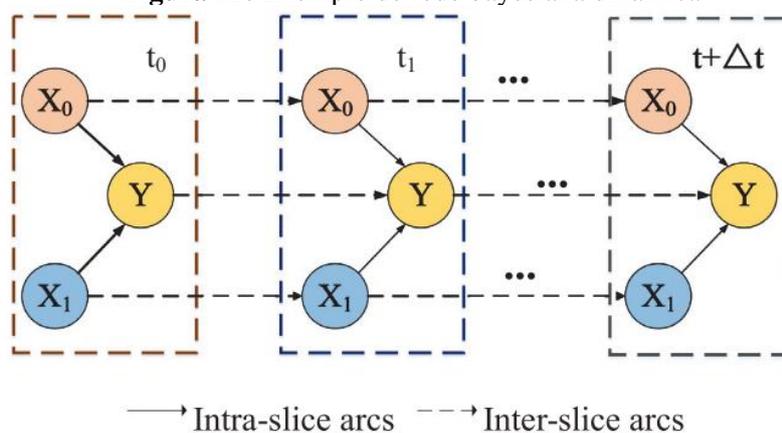
## 2.2 MODELAGEM VIA REDE BAYESIANA DINÂMICA

A rede bayesiana dinâmica (RBD) é uma modelagem derivada da rede bayesiana capaz de gerar uma relação temporal entre os nós, isto é, também é um grafo acíclico direcionado, conectado por arcos direcionados entre as variáveis (nós), entretanto as variáveis estão em momentos diferentes de tempo. Portanto, as variáveis do tempo anterior são nós pais das posteriores. A rede bayesiana dinâmica é composta por duas partes, a primeira formada por uma rede estática, que é descrita pelas relações das variáveis ao mesmo tempo; e a segunda é uma rede de transição, descrevendo como as variáveis nos tempos anteriores afetam as variáveis atuais (ZENG; GE, 2021). Utilizando a técnica de rede bayesiana dinâmica, é possível realizar uma análise ao longo do tempo, considerando as interrelações entre os eventos. Essa rede incorpora dependências temporais para modelar o comportamento dinâmico das variáveis consideradas.

A RBD é uma classe da rede bayesiana que representa processos estocásticos. Um conjunto de rede bayesiana (RB) forma uma rede bayesiana dinâmica, em que cada uma dessas redes representam um estado da  $i$ -ésima etapa do tempo. De  $i$  a  $i+1$ , as partes da RB são conectadas por arestas acíclicas. Caso as tabelas de probabilidades condicionais e a estrutura do modelo permaneçam inalteradas, a rede é denominada como homogênea (LEE; CHOI, 2020). Portanto, a rede bayesiana dinâmica é representada por uma sequência de *time-slice* (intervalos de tempo) e *links* temporais. Os arcos ligam as séries temporais chamadas de *time-slice* e nunca retornam para o *time-slice* anterior. Isso indica que a tabela de probabilidade condicional depende do tempo para cada nó avaliado. Em cada *slice* (intervalo) há uma rede bayesiana estática que descreve a variável no tempo correspondente, e o *link* temporal entre as variáveis em diferentes *slices* representa a dependência temporal probabilística. A tabela de probabilidade condicional de cada variável na rede dinâmica pode ser calculada de forma independente, facilitando a interpretação (HU *et al.*, 2011; WU *et al.*, 2016).

Consideremos um exemplo simples com três nós, sendo  $X_0$  e  $X_1$  nós pais do nó  $Y$  (ZHANG *et al.*, 2018). O nó  $Y$ , por exemplo, não depende somente dos nós pais no seu *time-slice*, que está representado pela ligação dentro do próprio *time-slice*, mas também dos nós pais no *time-slice* anterior, presente pela ligação entre os *time-slices*. Os *links* dentro do mesmo *time-slice* são chamados de *intra-slices*, e entre dois *time-slices* são conhecidos como *inter-slices* (CAI *et al.* 2013b), como apresentado na Figura 12, que contém uma rede bayesiana dinâmica com dois *time-slices*. As conexões realizadas no mesmo tempo são consideradas como uma ação instantânea, enquanto a conexão durante um *time-slice* é uma ação variada no tempo (WANG *et al.*, 2021; CAI *et al.*, 2021).

**Figura 12:** Exemplo de rede bayesiana dinâmica



Fonte: Chang *et al.* (2019)

A relação de dependência e condicionalidade dos nós dos *time-slices* só ocorre entre o *time-slice* atual e o previamente anterior, isto é, os *links* entre os nós só se relacionam com os dois *time-slices* sequenciais. Essa propriedade é conhecida como propriedade de Markov (CAI; LIU; XIE., 2017). Sendo assim, a equação 17 representa a distribuição da probabilidade da rede bayesiana dinâmica descrita, considerando a probabilidade de Markov (PANG, YU e Song, 2021).

$$P((x_1, x_2, \dots, x_n) = P(x_{t=0}) \prod_{t=0}^{t-1} P(x_t | x_{t-1}) \quad (17)$$

Portanto, existem dois princípios para a construção da rede bayesiana dinâmica interconectada em *time-slices* pelas redes bayesianas estáticas. Primeiramente, o sistema é assumido como a primeira ordem Markoviana,  $P(X_t | X_1, \dots, X_{t-1}) = P(X_t | X_{t-1})$ , e o segundo é que a probabilidade de transição  $P(X_t | X_{t-1})$  é a mesma em todo tempo T total analisado.

Propondo Z como uma família de variáveis aleatórias  $x_1, x_2, \dots, x_n$ , o modelo de transição de um *time-slice* anterior para o atual *time-slice* de uma rede bayesiana dinâmica pode ser expresso, segundo Murphy (2002) por:

$$P(Z_t | Z_{t-1}) = \prod_{i=1}^n P(Z_{i,t} | Pa(Z_{i,t})) \quad (18)$$

Onde  $Z_{i,t}$  é o i-ésimo nó no intervalo de t e  $Pa(Z_{i,t})$  são os nós pais do nó de  $Z_{i,t}$  proveniente dele mesmo e do *time-slice* anterior. E n é o número de nós da rede.

A função de densidade de probabilidade conjunta de uma rede bayesiana dinâmica no tempo t=1 para N tempos é expressa como:

$$P(Z_{1:N}) = \prod_{t=1}^N \prod_{i=1}^n P(Z_{i,t} | Pa(Z_{i,t})) \quad (19)$$

Os nós do primeiro *time-slice*, ou primeira fração de tempo, possuem uma distribuição associada a cada estado do nó; já para o segundo *time-slice*, para cada um desses nós, é associada uma tabela de probabilidade condicional (TPC). Então, em uma

rede bayesiana dinâmica com T *slices*, a distribuição de probabilidade conjunta é obtida pela equação abaixo:

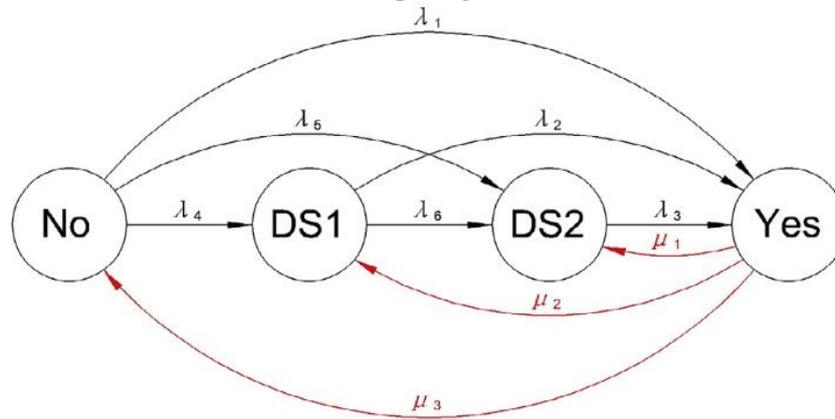
$$P(X_{1:T}^{1:N}) = \prod_{i=1}^N P_{B_1}(X_1^i | Pa(X_1^i)) \times \prod_{t=2}^T \prod_{i=1}^N P_{B \rightarrow}(X_t^i | Pa(X_t^i)) \quad (20)$$

A rede bayesiana dinâmica tem a capacidade de realizar previsões sobre as probabilidades futuras de um nó ao utilizar inferência estatística. Essa análise dinâmica é realizada através da transmissão de informações de um nó para o outro e, com isso, antecipa o valor de qualquer nó desejado em intervalos de tempo futuros, com base nos dados observados no tempo atual. Esse tipo de análise pode ser constatada pelo estudo de Murphy (2002).

As cadeias de Markov podem ser utilizadas nas redes bayesianas dinâmicas para modelar as relações causais entre os nós nos intervalos de tempo. A cadeia de Markov é um modelo estocástico que apresenta as sequências dos estados com probabilidades de transição de estado, dependendo apenas de um número finito de nós anteriores. As probabilidades de transição são dadas pela função de distribuição de probabilidade conjunta. A rede dinâmica permite descrever espaços de estados combinatórios de forma compacta em vários tempos. Por isso, o modelo do parâmetro do *inter-slices* é a probabilidade de falha do processo que segue a propriedade de Markov, em que a probabilidade é determinada pelos nós entre os *time-slices* t e t+Δt. (CAI; LIU; XIE, 2017).

Assim como é permitido pela cadeia de Markov, a rede bayesiana também se utiliza do princípio de que uma variável pode ser representada em vários estados de funcionamento e, por isso, pode haver um extenso diagrama de estados de transição para cada variável estudada (SALEM; MULLER; WEBER, 2007). Uma forma de representar essas transições está apresentada na Figura 13, em que o estado No significa o estado de perfeito funcionamento, enquanto o Yes indica a falha, e as siglas Ds1 e Ds2 são os estados degradados sequenciais. Assim como apresentado anteriormente, os cálculos para as probabilidades, as taxas de falha e reparo podem ser usados também para o processo, no cálculo das probabilidades. A Figura 13, é apresentado um exemplo em que as taxas de falha para cada um dos estados estão representadas pelas siglas  $\lambda_i$ , e  $\mu_i$  sendo as taxas de reparo.

**Figura 13:** Diagrama de transição dos estados dos componentes com múltiplos estados de degradação



Fonte: Cai *et al.* (2013c).

A rede bayesiana dinâmica também pode ser estudada quando há a ocorrência de testes e manutenções que ocorrem em sistema operacionais. De acordo com ISA-TR84.00.03 (2002), o teste é a execução de uma ação em um sistema, subsistema ou canal para confirmar se ele está desempenhando a função que foi a ele definida. Os testes conhecidos como *proof test* ou teste de prova, são atividades desempenhadas para verificar o nível de integridade de segurança de um sistema de segurança com o objetivo de identificar todas as falhas perigosas e não detectadas. Esses testes podem ser parciais ou completos. O teste completo ocorre em intervalos de tempo destinados a revelar todas as falhas latentes do equipamento ou do componente que está sendo testado. Na maioria das vezes isso requer o desligamento do sistema, o que afeta a produção dada a paralisação. O teste parcial, entretanto, permite que seja realizado atividades sem comprometer a produção, ao mesmo tempo manter a integridade do sistema. O objetivo é projetar um teste de um ou mais modos de falha específicos de um canal sem perturbar significativamente o equipamento sob controle (OCHENI, 2015).

Esses testes podem ser de dois tipos, os perfeitos e os imperfeitos (IEC-61508, 2009). Os testes considerados perfeitos são realizados em condições similares as situações de demandas reais, conseguem revelar todas as falhas perigosas e não detectadas do sistema e essas falhas são reparadas perfeitamente, levando o componente a uma condição “tão boa quanto nova”. Entretanto, em algumas ocasiões, alguns fatores podem afetar o teste ou o teste pode não cobrir todos os aspectos conduzindo um a algumas falhas não detectadas. Nesse teste, a função de segurança não é restaurada a “tão boa quanto nova”, e portanto, a probabilidade de falha vai aumentar (IEC-6151, 2014). Os testes imperfeitos podem ser categorizados em incompletos ou incorretos. Os

testes incompletos são definidos como a probabilidade que todas as falhas não serem reveladas por uma limitação do teste. Enquanto os incorretos estão associados a execução correta da equipe de teste conforme o especificado (BUKOWSKI e VAN BEURDEN, 2009). Os testes parciais também podem ser considerados como testes imperfeitos.

A fração de falhas detectadas pelos testes é chamado de cobertura do teste de prova ou *proof test coverage*. As falhas perigosas não detectadas ( $\lambda_{DU}$ ) são divididas em duas partes baseadas nas falhas reveladas durante o teste de prova, uma é a taxa de falhas perigosas não detectadas revelada chamada de  $\lambda_{DU}^r$ , e a taxa de falhas e as não reveladas,  $\lambda_{DU}^{nr}$  (RAUSAND, 2014).

$$\lambda_{DU} = \lambda_{DU}^r + \lambda_{DU}^{nr} \quad (21)$$

O *proof test coverage* é ilustrada pela seguinte equação:

$$PTC = \frac{\lambda_{DU}^r}{\lambda_{DU}} \quad (22)$$

A taxa de falhas reveladas e não reveladas expressas em relação ao PTC e a taxa de falha perigosa e não detectada é dada por:

$$\lambda_{DU}^r = PTC * \lambda_{DU} \quad e \quad \lambda_{DU}^{nr} = (1 - PTC) * \lambda_{DU} \quad (23)$$

A probabilidade de falha por demanda para tempos independentes PFD de um sistema pode ser então escrito como:

$$PFD(t) = PFD^r(t) + PFD^{nr}(t) \quad (24)$$

Devido às vantagens de a técnica da rede bayesiana aceitar variados estados de funcionamento, incluindo processos de reparo, o avanço com uso da dinâmica traz a aplicabilidade dessa técnica para variados sistemas, em diversos setores do mercado.

Essa técnica permite fazer a relação entre um evento e suas causas, entretanto, quando se deseja analisar a ocorrência de um evento e suas consequências, outras técnicas são utilizadas, como exemplo, a árvore de evento, que será apresentada na subseção seguinte.

## 2.5 INFERÊNCIA BAYESIANA

A inferência estatística tem a finalidade de estimar sobre uma população, a partir de uma amostra dela. A partir dessa amostra conhecida, os dados são chamados de

variáveis aleatórias. Essas variáveis possuem um comportamento chamado de distribuição. A inferência clássica considera que os dados observados são independentes e igualmente distribuídos, definidos pela função descrita na equação 25, sendo  $(x_1, x_2, \dots, x_n)$  os dados da amostra e  $\theta$  o parâmetro de interesse desconhecido:

$$g(x_1, x_2, \dots, x_n; \theta) = \prod_{i=1}^n f(x_i | \theta) \quad (25)$$

A diferença entre a inferência clássica e bayesiana é que a primeira considera que o parâmetro de interesse é uma constante fixa, enquanto na outra esse parâmetro é uma quantidade aleatória. Além disso, a bayesiana não se baseia em frequência de dados, isto é, não é necessário que um evento ocorra várias vezes para que seja possível mensurar a probabilidade de esse evento ocorrer. Por esse motivo, a inferência bayesiana pode ser utilizada em análise de eventos raros.

Com o avanço tecnológico dos equipamentos de alta confiabilidade, poucos são os dados existentes sobre a falha de um sistema específico, tornando-se difícil a obtenção da probabilidade de falha por meio da estatística clássica, que presume os dados sendo independentes e igualmente distribuídos (iid). Para suprir a deficiência de não se terem dados homogêneos disponíveis e se permitir a consideração de todas as informações possíveis para a estimativa de parâmetros de interesse, o conceito da inferência bayesiana é útil. Ela é capaz de incorporar informações não empíricas para a estimativa de interesse (KELLY; SMITH, 2011). Essa abordagem permite a consideração de vários tipos de informações em diferentes fontes, como as opiniões de especialistas, dados de campo específicos e dados de campo oriundos de sistemas similares em um mesmo processo de estimação (SIU; KELLY, 1998).

Na abordagem bayesiana, os dados são caracterizados como observações coletadas no processo de estudo, estando eles sujeitos a incertezas. Essas incertezas ocorrem devido a erros de imprecisão de medidas, de interpretação, entre outros que podem ocorrer durante o levantamento dos dados. A partir de uma organização dos dados, manipulação ou análise, são geradas informações que têm por objetivo agregar conhecimentos sobre o componente ou sistema de interesse (KELLY; SMITH, 2009).

A inferência bayesiana é um método de inferência estatística que permite estimar parâmetros através da derivação da distribuição *a priori*, conhecida como *a posteriori*,

que é formada por meio de combinações de distribuições *a priori* e de funções de verossimilhança. Portanto, ela fornece uma estimativa mais precisa dos parâmetros, já que utiliza as informações *a priori* dos parâmetros e dos dados contidos de diferentes fontes integradas (PAN; YONTAY, 2016; YU; KHAN; VEITCH, 2017).

### 2.5.1 Modelagem Bayesiana Hierárquica

Um exemplo de modelagem que utilizar inferência bayesiana é a modelagem bayesiana hierárquica. Ela permite definir os parâmetros de forma flexível e pode lidar com diferentes distribuições de erros e efeitos aleatórios (CRESSIE et al., 2009). Esse modelo possibilita um agrupamento parcial de informações, dando a opção de agrupar dados de diferentes grupos ou fontes (MATSUBA et. al, 2023. Essa modelagem tem uma estrutura matemática para identificar a incerteza dos parâmetros de um modelo, atribuindo uma distribuição de probabilidade *a priori* com hiperparâmetros a serem identificados usando os dados disponíveis.

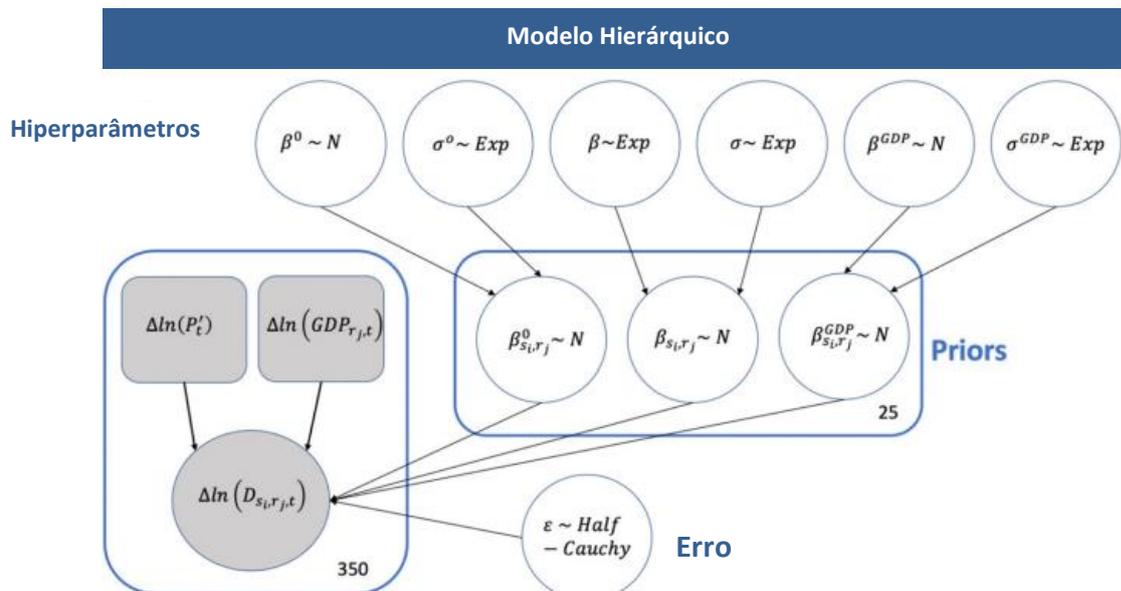
O nome hierárquico é proveniente dos múltiplos níveis para a estimativa da probabilidade *a posteriori* dos parâmetros de interesse. Os modelos hierárquicos podem ser usados para fazer inferências combinadas, em que os domínios (ou seja, parâmetros variáveis) são tratados separadamente, mas são calculados ao mesmo tempo. O benefício é que as distribuições em nível populacional são informadas pelo conjunto de dados completos, composto por vários domínios. No agrupamento parcial, certos parâmetros podem variar entre domínios, que estão correlacionados pelo condicionamento das variáveis pais à nível da população (DARDENO et. al, 2024). Sendo assim, os modelos hierárquicos podem estimar as características preditivas para uma previsão individual e sua média no nível de grupos. Por isso, os modelos hierárquicos são contextuais, ou seja, eles podem considerar o efeito específico de cada grupo local, mas também a média global, que informa ainda mais a estimativa local (BHUWALKA et. al, 2023).

O modelo bayesiano hierárquico possui, como princípio, especificar o modelo probabilístico de um dado observado  $y$  e a distribuição *a priori* para os parâmetros não observáveis  $\theta$  desse modelo. Isto é, os dados  $y$  obedecem uma distribuição com uma função de densidade de probabilidade dada por  $f(y|\theta)$ , ou sob a existência de variáveis exploratórias observáveis  $f(y|x, \theta)$  (DEDECIUS; ETTLER, 2014).

Os elementos fundamentais da inferência bayesiana são a função de verossimilhança e as distribuições *a priori* e *a posteriori*. A função de verossimilhança

é a probabilidade condicional que contém informações sobre os dados para cada variável de interesse. Ela traz a característica do modelo que representa os dados existentes sobre o parâmetro. A distribuição *a priori* são as crenças ou conhecimento existente sobre o valor incerto de um parâmetro, o parâmetro de interesse ( $\theta$ ). *Priors* agregam valor porque permitem que um modelo bayesiano estime o intervalo confiável para um parâmetro com mais rapidez, sem a necessidade de pesquisar em todo o espaço dos números reais. *Priors* informam a primeira estimativa dos valores dos parâmetros, melhorando a estimativa quando os dados são limitados. São usadas distribuições de probabilidade ampla como prioritárias para minimizar os vieses nas estimativas dos parâmetros (BHUWALKA *et. al*, 2023). As hiperparâmetros são utilizadas no modelo bayesiano para inicializar o modelo de forma que ele encontre melhores médias e desvios padrões (GELMAN, 2006). A Figura 14 mostra uma representação gráfica do modelo bayesiano hierárquico com as variáveis dependentes e independentes, assim como os seus parâmetros (*priors* e hiperparâmetros).

**Figura 14:** Estrutura gráfica de representação de um modelo hierárquico



As relações entre *priori* e hiperparâmetros são definidas de acordo com Gelman (2006) apresentada no Quadro 2. Um exemplo, é o parâmetro de interesse beta ( $\beta$ ) que é formado pelas hiperparâmetros para a média, definido por  $\beta^0$ , e para o desvio padrão, estabelecido pelo  $\sigma^0$ . Os hiperparâmetros são definidos por outras distribuições, como apresentado no Quadro 2 na primeira linha e segunda coluna, para a média ( $\beta^0$ ) representada por uma distribuição normal com média e desvio padrão sendo zero e 1, e

o desvio padrão ( $\sigma^0$ ) do parâmetro definido por uma distribuição exponencial com lambda valendo 1.

**Quadro 2:** Exemplo de *Prior e Hiperparâmetros*

<i>Priors</i>	<i>Hiperparâmetros</i>
$\beta_{s,r}^0 \sim \text{Normal}(\beta^0, \sigma^0)$	$\beta^0 \sim \text{Normal}(0,1)$ $\sigma^0 \sim \text{Exp}(1)$
$\beta_{s,r} \sim \text{Normal}(\beta, \sigma)$	$\beta \sim \text{Normal}(0,1)$ $\sigma \sim \text{Exp}(1)$

Os parâmetros de uma distribuição *a priori* serão governados por hiperparâmetros. Essa *priori* pode ser classificada como informativa e não informativa (LEONI *et al.*, 2021). Quando há poucos dados sobre um parâmetro, a indicação é usar uma *priori* não informativa. O motivo associado a isso é que, quando utilizamos esse tipo de *priori*, ela interfere pouco na verossimilhança, e a função fica pouco enviesada com essa informação e com alta incerteza, ou seja, não tem forte influência sobre a *posteriori*, o que permite ter uma atualização bayesiana dependente dos dados. Isso permite que a *posteriori* seja coberta pela incerteza dos dados, mas também reflete melhor a sua natureza. A distribuição não informativa permite que os valores dos hiperparâmetros sejam gerados cobrindo todas as possibilidades de distribuição de dados. A distribuição uniforme é um exemplo de distribuição não informativa de hiperparâmetros, em que é atribuída a mesma probabilidade para os valores dentro de um mesmo intervalo (YU; KHAN; VEITCH, 2017). Já a *priori* informativa realiza o cálculo de probabilidade *a posteriori* reduzindo a incerteza, ou seja, aumentando a precisão da estimativa da probabilidade. Portanto, quando possível, *a priori* deve conter o máximo de informações para poder gerar mais precisão (WILSON; FRONCZYK, 2017; JIN, 2019; KONG *et al.*, 2020). A *posteriori* é o conhecimento atualizado sobre o parâmetro após *a priori* e os dados observados. A Figura 15 possui uma representação da modelagem hierárquica por meio de rede bayesiana, em que  $\alpha$  e  $\beta$  são hiperparâmetros.

A distribuição *a priori*  $\pi(\theta)$  contém todas as informações disponíveis *a priori* sobre o parâmetro inferido  $\theta$ . Ele pode ser obtido a partir de medidas anteriores de um especialista ou alternativamente ter uma forma não informativa. A função de densidade de probabilidade *a priori* é atualizada pelas novas informações providas por  $x$  e  $y$ , seguindo a regra de bayes (DEDECIUS; ETTLER, 2014):

$$\pi(\theta|x, y) = \frac{f(y|x, \theta)\pi(\theta)}{\int f(y|x, \theta)\pi(\theta)d\theta} \quad (26)$$

Onde a integral:

$$q(y|x) = \int f(y|x, \theta)\pi(\theta)d\theta = \int f(y, \theta|x)d\theta \quad (27)$$

Para a equação 27 é assumido que o espaço a ser considerado é  $\theta$ . Isso serve como uma normalização constante, garantindo que o resultado da distribuição *a posteriori*  $\pi(\theta|x, y)$  seja adequado. Essa integral é também uma densidade preditiva de  $y$  dado  $x$  que é obtido como um valor esperado  $E_{\theta} [f(y|x, \theta)]$  sobre todos os valores admissíveis de  $\theta$ . O resultado da função de densidade de probabilidade *a posteriori* conhecida como  $\pi(\theta|x, y)$  envolve informações *a priori* e a contribuição provinda de dados observados.

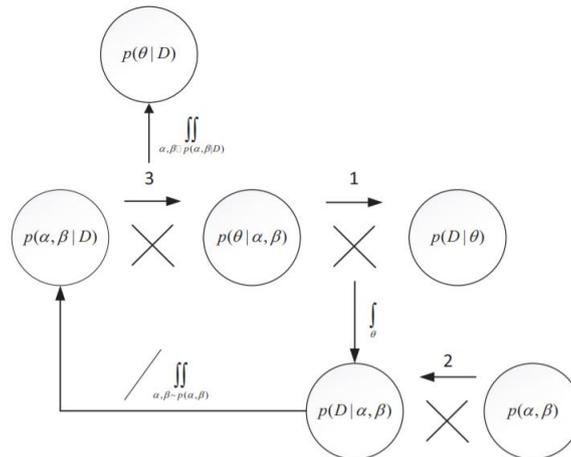
A abordagem bayesiana possui muitas vantagens decorrentes da consistência teórica. Algumas das vantagens importantes para a modelagem da confiabilidade são:

- Incerteza: é um aspecto inerente à informação, é consistentemente envolvida na modelagem. Por exemplo, a distribuição *a posteriori* de  $\theta$  naturalmente expressa sua incerteza em termo de variância.
- Assintótico: alguns modelos são fortemente baseados nos resultados assintóticos, entretanto a abordagem bayesiana produz resultados com qualquer tamanho da amostra, dado o conceito de funcionalidade.
- Modelagem dinâmica: é um aspecto relacionado com antecedentes conjugados. Ela exige rastreamento de parâmetros (DEDECIUS; NAGY; KÁRNÝ, 2012).
- Seleção e combinação de modelos: é possível combinar seus resultados, a fim de melhorar a modelagem e, por isso, é um diferencial entre modelos alternativos existentes (RAFTERY; KÁRNÝ, M.; ETTLER, 2010).

Como a modelagem bayesiana hierárquica é uma ferramenta utilizada em casos em que as informações existentes sobre um parâmetro são disponíveis em várias fontes distintas, desde dados existentes à opinião de especialistas, ocorre a atualização do parâmetro de interesse considerando as incertezas dessas fontes de informação (BROCCARDO *et al.*, 2017). O cálculo *a posteriori* informativo, por exemplo, é dividido em três passos, como ilustrado pela Figura 15, em que  $D$  é o conjunto de

dados,  $\theta$  é o vetor de parâmetros de interesse,  $\alpha$  e  $\beta$  são os vetores de hiperparâmetros da distribuição *a priori* do verto de parâmetros,  $p(\alpha, \beta)$  é a distribuição *a priori* dos hiperparâmetros,  $p(D|\theta)$  é a verossimilhança sobre  $\theta$  e  $p(D|\alpha, \beta)$  é a verossimilhança sobre o hiperparâmetros. As distribuições *a posteriori* dos hiperparâmetros e do parâmetro são dadas por  $p(\alpha, \beta|D)$  e  $p(\theta|D)$ , respectivamente.

**Figura 15:** Estrutura lógica do modelo bayesiano hierárquico



**Fonte:** Yu *et al.* (2017)

1º passo: Obter a função de verossimilhança dos hiperparâmetros

$$l(D|\alpha, \beta) = \int l(D|\theta)p(\theta|\alpha, \beta)d\theta \quad (28)$$

2º passo: Calcular a distribuição *a posteriori* dos hiperparâmetros por meio do teorema de bayes

$$p(\alpha, \beta|D) = \frac{p(\alpha, \beta)l(D|\alpha, \beta)}{\iint p(\alpha, \beta)l(D|\alpha, \beta) d\alpha d\beta} \quad (29)$$

3º passo: Calcular a distribuição *a posteriori* do parâmetro de interesse, considerando os dados pelo processo de marginalização dos hiperparâmetros. O cálculo da integral dupla é solucionado pela aplicação da simulação de Monte Carlo Chain (MCMC), tendo em vista a dificuldade de resolução

$$p(\theta|D) = \iint p(\theta|\alpha, \beta) p(\alpha, \beta|D) d\alpha d\beta \quad (30)$$

Essa modelagem é aplicada para gerar um resultado mais fidedigno e melhorar a capacidade de calcular a probabilidade de falha junto à rede bayesiana, ao permitir lidar

com a incerteza de dados escassos com múltiplas fontes de dados. E um desses dados é a opinião se especialista que foi tratado na próxima subseção.

### 2.5.2 Tratamento Bayesiano para a Opinião de Especialista

Quando o parâmetro que se deseja estimar possui uma amostragem de dado escassa ou tem uma baixa frequência de ocorrência de falhas, gera poucas informações sobre a confiabilidade, e, portanto, sua estimativa pode vir a depender também da opinião de especialistas. Para que se tenha uma estimativa de probabilidade realista e imparcial, nesse caso, é necessário o uso do processo de modelagem com variabilidade de fontes, já que as técnicas de estimativa convencional, sendo elas paramétricas ou não, confiam fortemente na disponibilidade da amostra de dados, então sua estimativa de probabilidade será verdadeira de acordo com o aumento no número de dados existentes (DROGUETT, GROEN e MOSLEH, 2004).

Um exemplo de parâmetro é a taxa de falha de um sistema que é a caracterização frequentemente usada para definir a capacidade do sistema não desempenhar a sua função pretendida. Esse parâmetro não é uma entidade objetiva, todavia, as taxas são expressões dotadas de incertezas sobre o funcionamento do sistema baseado no comportamento de falha ao longo do tempo (SINGPURWALLA, 1988). Como a taxa de falha é associada a um sistema, pode-se considerar a variabilidade das taxas de falha entre uma população de sistemas. Uma forma de representar a variabilidade é pela forma de distribuição de probabilidade, chamada de distribuição de variabilidade populacional. É assumido que a distribuição da variabilidade populacional pode ser descrita por um membro de uma determinada família de modelos de distribuição paramétrica. A incerteza associada a distribuição é expressa em forma de uma distribuição de probabilidade sobre os membros dessa família de modelos (DROGUETT e MOSLEH, 2004).

Segundo Droguett, Groen e Mosleh (2004), a variabilidade populacional de um parâmetro pode ser baseada em alguns tipos de fontes, são elas:

(E1) O analista, como o estado de conhecimento sobre a distribuição *a priori*, em que estão contidos engenheiros experientes;

(E2) Dados de campo disponíveis por meio de experiências operacionais, com os sistemas similares ao que o parâmetro de interesse é usado;

(E3) Estimativas ou distribuições por meio de várias fontes utilizadas, como o banco de dados de confiabilidade e julgamento de especialistas. Essas estimativas

consistem em pontos de estimação com “a melhor estimativa” ou uma variação de valores centralizada sobre a melhor estimativa. A distribuição pode expressar essa variação de valores com o uso da média ou mediana, representando a melhor estimativa das fontes.

Para o tipo E3, cuja estimativa do parâmetro de interesse será estabelecida por meio da opinião de especialistas e de dados de campo, será preciso estabelecer alguns aspectos. Considerando o parâmetro de interesse sendo a taxa de falha ( $\lambda$ ), então, para os dados de campo, é preciso conter o número de falhas de cada equipamento e o tempo de operação de cada um. Enquanto para a opinião de especialistas é preciso ter a opinião mais provável e o fator de erro, que representa o grau de relevância da opinião – quanto maior for esse fator, menor é a sua relevância. A variabilidade da opinião do especialista é normalmente dada por meio de uma distribuição lognormal (DROGUETT; GROEN; MOSLEH, 2004; MARTINO, 1970; MOSLEH; APOSTOLAKIS, 1980; COOKE, 1991; MOSLEH, 1992).a

Assumindo, para fins de exemplificação,  $\varphi(x) = \varphi(x|\theta_1, \dots, \theta_r)$  é definido como o modelo de distribuição de variabilidade paramétrica, então a distribuição de probabilidade  $\pi(\theta_1, \dots, \theta_r)$  sobre os parâmetros do modelo pode ser usado para descrever a incerteza sobre a distribuição da variabilidade populacional. A estimativa da densidade de variabilidade populacional é dada por:

$$p(x) = \int \dots \int_{\theta_1, \dots, \theta_r} \varphi(x|\theta_1, \dots, \theta_r) \pi(\theta_1, \dots, \theta_r) d\theta_1 \dots d\theta_r \quad (31)$$

Portanto, a função de densidade estimada consiste em um mix ponderado de distribuições do modelo escolhido. Ao invés de ser formada por uma única “melhor” distribuição escolhida, é feita a partir do conjunto de distribuições possíveis dentro da definição do modelo, como por exemplo, os estimadores de verossimilhança.

A distribuição de variabilidade populacional usualmente é utilizada como distribuições *a priori* genéricas em procedimentos avaliados Bayesiano de acordo com Kaplan (1983) e Deely e Lindley (1981). A distribuição de probabilidade  $\pi(\theta_1, \dots, \theta_r|E_1, E_2, E_3)$  dos parâmetros do modelo de variabilidade  $\varphi(x|\theta_1, \dots, \theta_r)$  é condicional a  $E_1, E_2, E_3$ . Sendo assim, a distribuição de um sistema específico, condicional as fontes de informação ( $E_1, E_2, E_3$ ) com as evidências presentes em  $E_4$  é dada por:

$$\pi(x|E_1, E_2, E_3, E_4) = \frac{\int_{\delta} \varphi(x|\delta)\pi(\delta|E_1, E_2, E_3)d\delta}{\int_x P(E_4|X, E_1, E_2, E_3) \int_{\delta} \varphi(x|\delta)\pi(\delta|E_1, E_2, E_3)d\delta dx} \quad (32)$$

Em que  $\delta = \{\theta_1, \dots, \theta_r\}$ . A distribuição a posteriori dos parâmetros da variabilidade populacional baseado nas informações  $E_1, E_2, E_3$  é desenvolvido no teorema de Bayes é dada por:

$$\pi(x|E_1, E_2, E_3) = \frac{P(E_2, E_3|\delta, E_1)\pi_0(\delta|E_1)}{\int_{\delta} P(E_2, E_3|\delta, E_1)\pi_0(\delta|E_1)d\delta} \quad (33)$$

Em que  $P(E_2, E_3|\delta, E_1)$  é a verossimilhança da informação e a  $\pi_0(\delta|E_1)$  é a distribuição a priori de  $\delta$ .

Assumindo que os dados de  $E_2$  e as estimativas das fontes ( $E_3$ ) são independentes, a função de verossimilhança tornasse:

$$P(E_2, E_3|\delta, E_1) = P(E_2|\delta, E_1)P(E_3|\delta, E_1) \quad (34)$$

Em que a parte da direita é a função de verossimilhança dos dados ( $E_2$ ) e o segundo é a verossimilhança para estimativa das informações das opiniões. Portanto, essa equação em termo de verossimilhança das informações para cada sistema pode ser definida como:

$$P(E_2, E_3|\delta, E_1) = \prod_{i=1}^n P(E_{2i}|\delta, E_1)P(E_{3i}|\delta, E_1) \quad (35)$$

Em que  $P(E_{2i}|\delta, E_1)$  é a probabilidade de evidências observadas  $E_{2i}$  e  $E_{3i}$ , para a i-énésima evidência para os n sistemas assumindo que o conjunto de parâmetros de uma curva de variabilidade populacional é dada por  $\delta$ .

Em alguns casos, a medida de confiabilidade para o i-énésimo sistema,  $x_i$ , não é conhecida. Sabendo-se que  $x_i$  é um dos possíveis valores de uma variável X. Além disso, sabe-se que X é uma distribuição de acordo com  $\varphi(x|\delta)$  sendo que  $\delta$  é desconhecido. Portanto, para calcular a probabilidade dos dados observados  $E_2$  e  $E_3$  é dado por:

$$P(E_2, E_3|\delta, E_1) = \int_x P(E_{2i}|\delta, E_1)P(E_{3i}|\delta, E_1) \varphi(x|\delta)dx \quad (36)$$

Considerando que a medida de confiabilidade pode assumir todos os possíveis valores.

Em casos em que as informações de  $E_2$  e  $E_3$  são desassociados, a equação 36 para o cálculo da verossimilhança com os dois pedaços de evidências, em que os dados observados do sistema i e a estimativa do sistema j, pode ser escrita da seguinte maneira:

$$P(E_{2i}|\delta, E_1)P(E_{3j}|\delta, E_1) = \left[ \int_x P(E_{2i}|\delta, E_1)\varphi(x|\delta)dx \right] \left[ \int_x P(E_{3j}|\delta, E_1)\varphi(x|\delta)dx \right] \quad (37)$$

Assumindo que as fontes para a estimativa pela opinião de especialistas para o sistema j e dos dados observados para o sistema i são diferentes.

Ao utilizar a opinião de especialistas para estimar o parâmetro desconhecido, a função de verossimilhança  $\mathcal{L}(x|\theta)$  será considerada como a densidade de probabilidade do conjunto de estimativa dos especialistas; e a distribuição do elemento de interesse x será uma distribuição de parâmetros  $f(x|\theta)$  com parâmetros entre  $\{\theta_1 \dots \theta_m\}$ . Pode-se assumir que os especialistas são dependentes ou independentes. Ao considerar especialistas independentes, a estimativa do i especialista é um pedaço das informações sobre a variável x, ou seja, a estimativa definida pelo especialista i para a variável x, dada por  $x_i^*$ , é um dos possíveis valores de x (COOKE, 1991).

$$\mathcal{L}(x_1^*, x_2^*, \dots, x_n^* | \theta) = \prod_{i=1}^n \mathcal{L}(x_i^* | \theta) \quad (38)$$

Considerando os especialistas independentes para estimar as medidas de confiabilidade como as taxas de falha e a probabilidade de falha, os dados  $\{(\lambda_i, \sigma_i) = i = 1, \dots, n\}$ , em que  $\lambda_i$  é fornecido pela opinião de especialistas i, e  $\sigma_i$  é o logaritmo do desvio padrão de  $\lambda_i$  representando a incerteza do especialista i, e n é o número dos especialistas. O valor de  $\sigma_i$  representa a confiança em relação a opinião do especialista i. Considerando o conhecimento sobre a taxa de falhas  $\lambda_i$  para cada especialista, é utilizado uma distribuição lognormal com a média sendo  $\ln \lambda$  para avaliar a probabilidade a verossimilhança das opiniões:

$$L(\lambda_i, \sigma_i | \lambda) = \frac{1}{\sqrt{2\pi\lambda_i\sigma_i}} e^{-\frac{1}{2\sigma_i^2}(\ln \lambda_i - \ln \lambda)^2} \quad (39)$$

Para o caso de uma taxa de falha possuindo variabilidade dada por  $\varphi(\lambda|\delta)$ , a probabilidade dos dados não condicionais ao valor desconhecido de  $\lambda$  é obtido pela média das probabilidades de todos os valores possíveis de  $\lambda$ . Considerando que a variabilidade populacional é representada por uma distribuição lognormal com os parâmetros  $\mu$  e  $\sigma$ , a equação acima pode ser desenvolvida pela probabilidade lognormal-lognormal dada por:

$$L(\lambda_i, \sigma_i | \mu, \sigma) = \frac{1}{\sqrt{\frac{1}{\sigma_i} + \frac{1}{\sigma^2}}} \frac{e^{-\frac{1}{2} \frac{(\ln \lambda_i - \ln \mu)^2}{(\sigma^2 + \sigma_i^2)}}}{\sqrt{2\pi} \sigma_i^2 \sigma \lambda_i} \quad (40)$$

Depois de definida a relação de dependência entre os especialistas, é necessário que o tomador de decisão venha a estabelecer o grau de conhecimento do especialista, ou seja, ele será deliberado como sendo perfeito ou imperfeito. Ao supor especialistas perfeitos, acredita-se que o valor estimado  $x_i$ , para todos os valores possíveis de  $x$ , seja exatamente aquela medida real. Com isso, a exatidão da estimativa do especialista é representada pela distribuição de probabilidade  $P_i$  que será estabelecida pela função  $\delta$ , sendo essa função a ser definida pelos dados existente, assim como a verossimilhança dada por (MOSLEH, 1992):

$$P_i(x_i^*) = \delta(x_i^* - x_i) \quad (41)$$

$$\mathcal{L}(x_i^* | \theta) = \int \delta(x_i^* - x_i) f(x|\theta) dx = f(x_i^* | \theta) \quad (42)$$

Isto é, a estimativa do especialista perfeito é equivalente a uma concretização da variável aleatória de interesse. Portanto, esses valores estimados são os mesmos encontrados pelos valores observados.

Outro caso é não confiar totalmente na opinião dos especialistas, considerando o especialista imperfeito. Então  $P_i$  é melhor estipulado como uma distribuição fixa para uma constante  $c$  e a verossimilhança dadas por (MOSLEH; APOSTOLAKIS, 1984):

$$P_i(x_i^*) = c$$

$$\mathcal{L}(x_i^*|\theta) = \int c f(x|\theta) dx = c$$

(43)

Isso ocorre devido  $f(x|\theta)$  ser uma função de densidade de probabilidade que integra a união. Nessa equação é possível ver que a opinião de especialistas não terá nenhum efeito na probabilidade *a posteriori*.

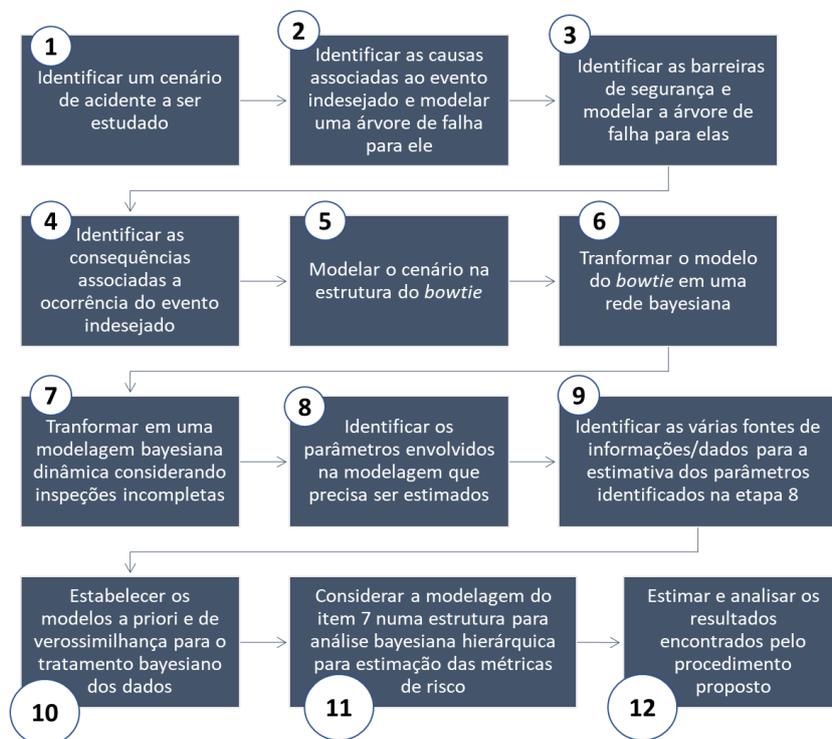
### 3 PROCEDIMENTO METODOLÓGICO

Essa seção apresenta o procedimento metodológico a ser aplicado no estudo proposto considerando um exemplo hipotético para facilitar a compreensão.

#### 3.1 ABORDAGEM METODOLÓGICA

O procedimento metodológico proposto consiste em construir um processo de análise de risco dinâmica baseada na combinação do modelo *bowtie*, da rede bayesiana dinâmica e da modelagem bayesiana hierárquica com a inclusão e propagação de incerteza ao longo do tempo. A proposta consiste em estudar um evento indesejado e as probabilidades de ocorrência de suas consequências incluindo as barreiras de mitigação. Esse capítulo apresenta o procedimento proposto para buscar alcançar os objetivos abordadas na introdução, que são principalmente: (i) Estruturar um modelo de *bowtie* dinâmico que engloba as metodologias da rede bayesiana dinâmica, modelagem bayesiana hierárquica e árvore de evento e (ii) Calcular as probabilidades de ocorrência das consequências de um evento indesejado a partir da modelagem de *bowtie* dinâmico. A Figura 16 apresenta o fluxograma que caracteriza as etapas do procedimento metodológico proposto.

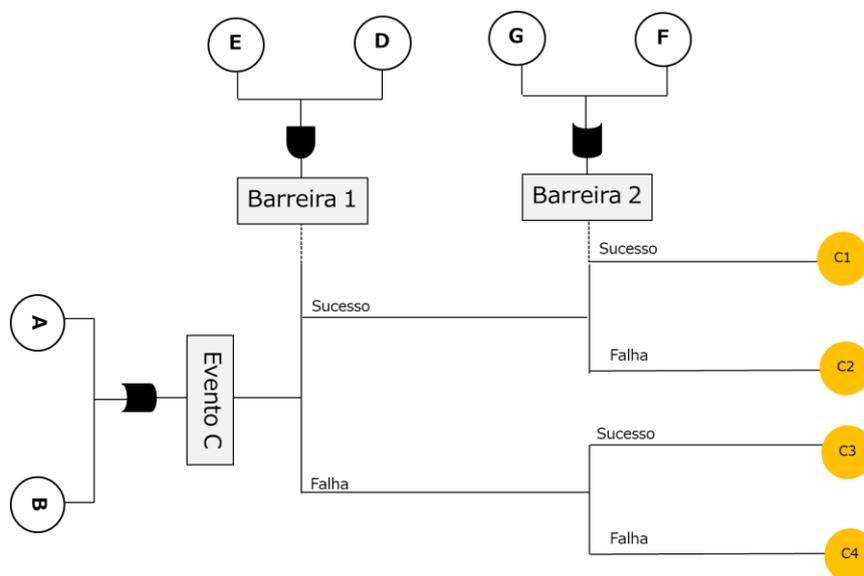
**Figura 16:** Fluxo do procedimento metodológico



Fonte: A autora (2023)

Com a finalidade de facilitar a compreensão e demonstrar o ganho quantitativo gerado pelo processo metodológico proposto, essa seção apresenta com detalhe a análise de quatro hipóteses de aplicação utilizando um evento crítico como exemplificação, apresentado na Figura 17. Essas hipóteses correspondem à diferentes formas de avaliar o risco de acordo com a finalidade da pesquisa. O objetivo de realizar a análise dessas hipóteses é mostrar as vantagens alcançadas em cada uma em relação ao anterior, respondendo às seguintes perguntas (a) Qual o ganho gerado ao modelar o *bowtie* via rede bayesiana? (b) Qual o ganho ao transformar a rede bayesiana em rede bayesiana dinâmica? (c) Qual o ganho gerado com a modelagem da rede bayesiana dinâmica combinado ao modelo bayesiano hierárquico?

**Figura 17:** Estrutura do *bowtie* para o caso hipotético



**Fonte:** A autora (2023)

A Figura 17 ilustra a modelagem do *bowtie* para o exemplo hipotético do evento crítico que serviu de base para as hipóteses analisadas. O evento crítico é representado pelo evento indesejado C gerado pela ocorrência dos eventos básicos A e B representado por um portão lógico OR. Com a ocorrência da falha do evento C, as barreiras de segurança 1 e 2 são acionadas para controlar os impactos negativos gerados por esse evento. A barreira de segurança 1 possui os eventos básicos E e D conectados por um portão lógico AND, e a barreira 2, contém os eventos F e G como os básicos formada por uma lógica OR. O sucesso da barreira 1 e da 2 conduzem a ocorrência da consequência 1 (C<sub>1</sub>), enquanto com o sucesso da barreira 1 e a falha da barreira 2, a

consequência 2 ( $C_2$ ) ocorre. A falha da barreira 1 e o sucesso da barreira 2 permite a ocorrência da consequência 3 ( $C_3$ ), entretanto com a falha da barreira 2, a consequência 4 ( $C_4$ ) é gerada. Quando ocorre o sucesso do evento C, as barreiras não são acionadas e, portanto, a consequência gerada é um ambiente seguro, nomeada de  $C_0$ . A soma das consequências ( $C_0, C_1, C_2, C_3, C_4$ ) deve ser exatamente igual a 1, visto que são probabilidades em que contabiliza todos os possíveis caminhos de ocorrência das consequências, a partir do sucesso ou da falha do evento iniciador (Evento C). Além disso, as consequências são eventos mutuamente excludentes, isto é, são eventos que não podem acontecer ao mesmo tempo.

A estrutura das quatro hipóteses contém a identificação e construção do cenário de acidente em uma modelagem via *bowtie*, com o modelo de árvore de falha do evento indesejado, as barreiras de segurança e a montagem da árvore de evento. Essa estrutura compõe as etapas de 1 até 6 da Figura 16 apresentada anteriormente.

As quatro hipóteses possuem as seguintes características: (1) Na primeira situação hipotética é considerada a transformação das árvores de falha em rede bayesiana estática representada por uma taxa de falha constante sem o tratamento de incerteza associada aos dados existentes; (2) Na hipótese seguinte, a estrutura dinâmica foi adicionada ao processo, por meio da rede bayesiana dinâmica, visto que os processos operacionais são dinâmicos e há uma modificação nas probabilidades dos estados de cada evento ao longo do tempo, considerando uma inspeção/teste imperfeito. Essa análise dinâmica gera uma mudança nas probabilidades de ocorrência das consequências em cada intervalo. (3) Na terceira condição, para fins de comparação de resultados, a incerteza foi tratada à condição da primeira hipótese, considerando que os dados e informações coletadas são de fontes variadas, e por isso, possui uma incerteza em seus valores. (4) Na quarta e última hipótese, há o tratamento das incertezas às condições da segunda hipótese (considerando a condição dinâmica), sendo esse o procedimento metodológico proposto por essa tese. Em cada uma das hipóteses foi avaliado os resultados, sendo possível compará-los e, assim, analisar a evolução para responder as perguntas anteriores. O quadro 3 contém a síntese das diferenças entre as hipóteses.

**Quadro 3:** Quadro comparativo das hipóteses do procedimento metodológico

Hipótese	Rede Bayesiana	Taxa de Falha	Incerteza
Hipótese 1	Estática	Constante	Não tratada
Hipótese 2	Dinâmica	Constante	Não tratada

Hipótese	Rede Bayesiana	Taxa de Falha	Incerteza
Hipótese 3	Estática	Variável	Tratada
Hipótese 4	Dinâmica	Variável	Tratada

Para todas as hipóteses analisadas, a base de estudo é a rede bayesiana que possui como referência de informações o *bowtie*, que caracteriza a modelagem tradicional do cenário de risco hipotético. A conversão do *bowtie* em rede bayesiana possui como etapa inicial a construção da estrutura de rede e da tabela de probabilidade condicional que depende do estado de cada evento e a influência de cada um sobre o evento seguinte. A construção da rede bayesiana foi feita para todos os elementos que compõem o *bowtie*, isto é, o cenário como um todo, com o evento iniciador, as barreiras de segurança e as consequências. Os nós da rede são as variáveis aleatórias que possuem incerteza quanto a sua ocorrência, podendo ter mais de um estado. Para esse estudo, ela possui apenas dois, funcionando (sucesso) e não funcionando (falha), entretanto, pode haver mais. Após esse processo de conversão, é possível calcular a probabilidade de ocorrência das consequências baseado nos eventos anteriores. Esse processo foi analisado de forma dinâmica, na segunda e na quarta hipóteses.

Quando há a transformação em rede bayesiana dinâmica, o processo de conversão agrega uma análise das probabilidades condicionais de cada evento para cada intervalo de tempo, considerando a condição do estado do evento no tempo anterior. Esse processo de análise dinâmica contém as tabelas de probabilidade condicional ao longo do tempo.

A inclusão da modelagem bayesiana hierárquica na análise é feita por meio do tratamento da incerteza nos valores das taxas de falha dos eventos. As informações presentes em fontes variadas de informação, como as opiniões de especialistas e dados provenientes de sistemas similares, contém incertezas. Para essa modelagem foi utilizada um artifício computacional, em que essas incertezas foram tratadas nas distribuições de probabilidade dos eventos analisados.

As hipóteses possuem a seguinte sequência de ações para o cálculo da probabilidade de ocorrência das consequências devido a ocorrência do evento iniciador.

#### ***Hipótese 1***

- Conversão qualitativa do *bowtie* em uma rede bayesiana estática do evento indesejado (Evento C);

- Construção lógica da tabela de probabilidade condicional do evento C;
- Construção lógica da tabela de probabilidade condicional das barreiras de segurança;
- Construção lógica da tabela de probabilidade condicional das consequências do evento C;
- Cálculo da probabilidade de ocorrência das consequências do evento C, de acordo com o Teorema de Bayes.

### ***Hipótese 2***

- Utilizando da estrutura qualitativa construída na hipótese 1, a rede bayesiana estática é convertida em dinâmica considerando uma discretização temporal quando as inspeções/testes são realizadas durante o processo estudado. Para isso, a cadeia de Markov foi utilizada como um instrumento de apoio;
- Cálculo das probabilidades condicionais dos eventos associados ao evento C, considerando a ocorrência de inspeções/testes incompletos em cada intervalo de tempo;
- Cálculo das probabilidades condicionais das barreiras de segurança considerando a ocorrência de inspeções/testes incompletos em cada intervalo de tempo;
- Cálculo das probabilidades de ocorrência das consequências segundo o Teorema de Bayes.

### ***Hipótese 3***

- Utilizando da estrutura qualitativa construída na hipótese 1, rede bayesiana estática, a modelagem bayesiana hierárquica é adicionada ao processo ao incluir as evidências e a opinião de especialista nos dados referente as taxas de falha dos eventos. Por isso, é modelado um programa lógico para o cálculo da probabilidade de falha dos eventos básicos causadores do evento C e das barreiras de segurança;
- Cálculo da probabilidade de ocorrência do evento C com a incerteza associada a essas informações;
- Cálculo das probabilidades de falha das barreiras de segurança;
- Cálculo das probabilidades de ocorrência das consequências do evento C.

#### Hipótese 4

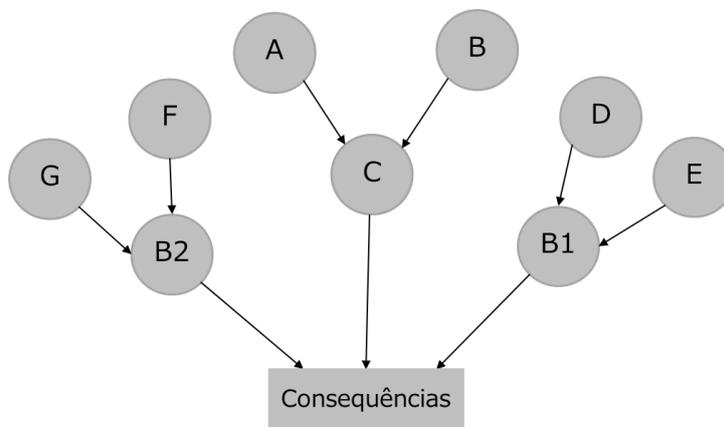
- Utilizando a lógica quantitativa da hipótese 3, a rede bayesiana dinâmica é utilizada no processo, em que é apoiada pela cadeia de Markov para o cálculo das probabilidades de falha dos eventos básicos causadores do evento C para o segundo intervalo de tempo;
- E finalizando para o terceiro intervalo de tempo.

A seguir são apresentados os cálculos detalhados realizados em cada hipótese.

#### 1ª Hipótese

Para a primeira hipótese proposta, os eventos básicos A, B, D, E, F e G são representados por uma distribuição exponencial com taxas de falha constante. Os valores das taxas de falha *a priori* de cada um dos eventos básicos estão apresentados na Tabela 7. O *bowtie* representado na Figura 17 são convertidas em uma rede bayesiana estática, apresentada na Figura 18.

**Figura 18:** Estrutura da rede bayesiana estática para o caso hipotético



**Fonte:** A autora (2023)

**Tabela 7:** Taxa de falha dos eventos básicos e das barreiras de segurança

Eventos	Taxa de Falha (/h)
Evento A	1.0E-4
Evento B	2.5E-4
Evento D	6.0E-5
Evento E	8.0E-5
Evento F	2.0E-5
Evento G	3.0E-5

**Fonte:** A autora (2023)

Para realização dos cálculos é assumida as seguintes premissas:

- (I) Os eventos possuem dois estados de ocorrência, sucesso e falha. O estado sucesso é quando os eventos de falha não ocorrem;
- (II) Os eventos podem ir para o estado de falha aleatoriamente;
- (III) Há a consideração de inspeção/teste no processo de análise do estudo ao longo dos intervalos de tempo (análise dinâmica), entretanto, não há retorno ao estado de sucesso quando o evento for para o estado de falha.

Em uma rede bayesiana, para o cálculo do evento C é necessário construir a tabela de probabilidade condicional (TPC). Essa tabela contém as possíveis combinações dos estados que cada evento pode se encontrar. Segundo Cai *et al.* (2013b), elas são calculadas a partir de m número de estados e de n eventos, portanto vai existir  $m^n$  combinações. Os eventos desse exemplo possuem dois estados, sucesso e falha, então são quatro combinações e a tabela vai possuir 4 possíveis estados representadas nas linhas. Essa tabela é construída a partir do conhecimento da configuração do sistema, série ou paralelo, lógica OR ou AND, respectivamente, e das probabilidades condicionais dos eventos, o sucesso e a falha, dado que o evento está em um dos dois estados. Para o cálculo da probabilidade do evento C, é utilizado a tabela de probabilidade condicional associada aos eventos A e B, construída a partir dos seus estados (sucesso e falha) com um portão lógico OR. Como o portão lógico é um OR, então o único momento que o evento C estará no estado de sucesso é quando os dois eventos, A e B, estiverem no estado de sucesso. A tabela de probabilidade condicional está apresentada na Tabela 8 e 9, sendo a Tabela 8 uma representação da lógica associada a ela e a Tabela 9 a tabela de probabilidade condicional em si, com suas respostas quantitativas. O valor 1 indica a ocorrência do evento.

**Tabela 8:** Estrutura lógica da tabela de probabilidade condicional do evento C.

Evento A	Evento B	Evento C	
		Sucesso	Falha
$P(A = \text{Sucesso})$	$P(B = \text{Sucesso})$	$P(C = \text{Sucesso} / A = \text{Sucesso e } B = \text{Sucesso})$	$P(C = \text{Falha} / A = \text{Sucesso e } B = \text{Sucesso})$
$P(A = \text{Sucesso})$	$P(B = \text{Falha})$	$P(C = \text{Sucesso} / A = \text{Sucesso e } B = \text{Falha})$	$P(C = \text{Falha} / A = \text{Sucesso e } B = \text{Falha})$
$P(A = \text{Falha})$	$P(B = \text{Sucesso})$	$P(C = \text{Sucesso} / A = \text{Falha e } B = \text{Sucesso})$	$P(C = \text{Falha} / A = \text{Falha e } B = \text{Sucesso})$
$P(A = \text{Falha})$	$P(B = \text{Falha})$	$P(C = \text{Sucesso} / A = \text{Falha e } B = \text{Falha})$	$P(C = \text{Falha} / A = \text{Falha e } B = \text{Falha})$

**Fonte:** A autora (2023)

**Tabela 9:** Tabela de probabilidade condicional do evento C.

Evento A	Evento B	Evento C	
		Sucesso	Falha
<i>Sucesso</i>	<i>Sucesso</i>	1	0
<i>Sucesso</i>	<i>Falha</i>	0	1
<i>Falha</i>	<i>Sucesso</i>	0	1
<i>Falha</i>	<i>Falha</i>	0	1

**Fonte:** A autora (2023)

Como os eventos A e B são independentes, então a probabilidade desses dois eventos estarem em cada um dos estados é dado pela equação:

$$P(A \text{ e } B) = P(A) * P(B) \quad (44)$$

Portanto, a probabilidade de o evento C ter sucesso é dado pela equação, considerando os dois estados dos eventos básicos A e B:

$$\begin{aligned}
 P(C = \text{Sucesso}) &= P(C = \text{Sucesso} / A = \text{Sucesso e } B = \text{Sucesso}) * P(A \\
 &= \text{Sucesso e } B = \text{Sucesso}) + P(C = \text{Sucesso} / A = \text{Sucesso e } B \\
 &= \text{Falha}) * P(A = \text{Sucesso e } B = \text{Falha}) + P(C = \text{Sucesso} / A \\
 &= \text{Falha e } B = \text{Sucesso}) * P(A = \text{Falha e } B = \text{Sucesso}) + P(C \\
 &= \text{Funcionar} / A = \text{Falhar e } B = \text{Falha}) * P(A = \text{Falhar e } B \\
 &= \text{Falha})
 \end{aligned} \quad (45)$$

As probabilidades dos eventos básicos A e B são representados por uma distribuição exponencial, por isso, a equação da probabilidade do estado de sucesso do evento C para um tempo T= 1200 horas é dado por:

$$\begin{aligned}
 P(C = \text{Sucesso}) \\
 &= 1 * (\exp(-1.E - 4 * 1200)) * (\exp(-2.5.E - 4 * 1200)) + 0 \\
 &* (\exp(-1.E - 4 * 1200)) * (1 - \exp(-2.5.E - 4 * 1200)) + 0 * (1 \\
 &- \exp(-1.E - 4 * 1200)) * (\exp(-2.5.E - 4 * 1200)) + 0 * (1 \\
 &- \exp(-1.E - 4 * 1200)) * (1 - \exp(-2.5.E - 4 * 1200))
 \end{aligned}$$

$$\begin{aligned}
 P(C = \text{Sucesso}) \\
 &= 1 * 0.8869 * 0.7408 + 0 * 0.8869 * 0.2592 + 0 * 0.1131 * 0.7408 \\
 &+ 0 * 0.1131 * 0.2592 = 0.6570 = 6.570 E - 1.
 \end{aligned}$$

(46)

E para a probabilidade de falha do evento C é dado por:

$$\begin{aligned}
 P(C = \text{Falho}) &= 0 * 0.8869 * 0.7408 + 1 * 0.8869 * 0.2592 + 1 * 0.1131 * 0.7408 \\
 &+ 1 * 0.1131 * 0.252 = 3.429 E - 1
 \end{aligned}
 \tag{47}$$

O processo de cálculo realizado para as barreiras de segurança é semelhante ao realizado para o evento C pela equação 45, para o mesmo intervalo de tempo (T= 1200 h). Para a barreira 1, o portão lógico AND é utilizado indicando que somente quando os dois eventos D e E estão falhos é que a barreira vai estar em estado de falha. Enquanto para a barreira 2, com o portão lógico de OR, assim como no evento C, somente estará em estado de sucesso quando os eventos F e G estarem no estado de sucesso. A equação 48 apresenta os cálculos do estado de sucesso para a barreira 1, a Tabela 10 apresenta a estrutura lógica da tabela de probabilidade condicional dessa barreira e a Tabela 11 contém os resultados encontrados.

$$\begin{aligned}
 P(\text{Barreira 1} = \text{Sucesso}) &= P(B1 = \text{Sucesso} / D = \text{Sucesso} e E \\
 &= \text{Sucesso}) * P(D = \text{Sucesso} e E = \text{Sucesso}) + P(B1 \\
 &= \text{Sucesso} / D = \text{Sucesso} e E = \text{Falha}) * P(D = \text{Sucesso} e E \\
 &= \text{Falha}) + P(B1 = \text{Sucesso} / D = \text{Falha} e E = \text{Sucesso}) * P(D \\
 &= \text{Falha} e E = \text{Sucesso}) + P(B1 = \text{Funcionar} / D = \text{Falhar} e E \\
 &= \text{Falha}) * P(D = \text{Falhar} e E = \text{Falha})
 \end{aligned}$$

$$\begin{aligned}
 P(\text{Barreira 1} = \text{Sucesso}) &= \\
 &= 1 * (\exp(-6.E - 5 * 1200) * (\exp(-8.E - 4 * 1200) + 1 \\
 &* (\exp(-6.E - 5 * 1200) * (1 - \exp(-8.E - 5 * 1200) + 1 * (1 \\
 &- \exp(-6.E - 5 * 1200) * (\exp(-8.E - 5 * 1200) + 0 * (1 \\
 &- \exp(-6.E - 5 * 1200) * (1 - \exp(-8.E - 5 * 1200)
 \end{aligned}$$

$$\begin{aligned}
 P(\text{Barreira 1} = \text{Sucesso}) &= 1 * 0.9305 * 0.9085 + 1 * 0.9305 * 0.09154 + 1 * 0.06947 \\
 &* 0.9085 + 0 * 0.06946 * 0.09154 = 0.9971 = 9.936 E - 1.
 \end{aligned}
 \tag{48}$$

**Tabela 10:** Estrutura lógica da tabela de probabilidade condicional da barreira 1

		Barreira 1	
Evento D	Evento E	Sucesso	Falha
$P(D = \text{Sucesso})$	$P(E = \text{Sucesso})$	$P(B1 = \text{Sucesso} / D = \text{Sucesso} e E = \text{Sucesso})$	$P(B1 = \text{Falha} / D = \text{Sucesso} e E = \text{Sucesso})$
$P(D = \text{Sucesso})$	$P(E = \text{Falha})$	$P(B1 = \text{Sucesso} / D = \text{Sucesso} e E = \text{Falha})$	$P(B1 = \text{Falha} / D = \text{Sucesso} e E = \text{Falha})$

		Barreira 1	
Evento D	Evento E	Sucesso	Falha
$P(D = Falha)$	$P(E = Sucesso)$	$P(B1 = Sucesso/D = Falha e E = Sucesso)$	$P(B1 = Falha/D = Falha e E = Sucesso)$
$P(D = Falha)$	$P(E = Falha)$	$P(B1 = Sucesso/D = Falha e E = Falha)$	$P(B1 = Falha/D = Falha e E = Falha)$

Fonte: A autora (2023)

**Tabela 11:** Tabela de probabilidade condicional da barreira 1.

		Barreira 1	
Evento D	Evento E	Sucesso	Falha
<i>Sucesso</i>	<i>Sucesso</i>	1	0
<i>Sucesso</i>	<i>Falha</i>	1	0
<i>Falha</i>	<i>Sucesso</i>	1	0
<i>Falha</i>	<i>Falha</i>	0	1

Fonte: A autora (2023)

E, assim a probabilidade de falha da barreira 1, possui o seguinte valor:

$$\begin{aligned}
 P(\text{Barreira 1} = \text{Falha}) &= \\
 &= 0 * (\exp(-6.E - 5 * 1200) * (\exp(-8.E - 4 * 1200) + 0 \\
 &* (\exp(-6.E - 5 * 1200) * (1 - \exp(-8.E - 5 * 1200) + 0 * (1 \\
 &- \exp(-6.E - 5 * 1200) * (\exp(-8.E - 5 * 1200) + 1 * (1 \\
 &- \exp(-6.E - 5 * 1200) * (1 - \exp(-8.E - 5 * 1200)
 \end{aligned}$$

$$\begin{aligned}
 P(\text{Barreira 1} = \text{Falha}) &= \\
 &= 0 * 0.9305 * 0.9085 + 0 * 0.9305 * 0.09154 + 0 * 0.06947 \\
 &* 0.9085 + 1 * 0.06946 * 0.09154 = 0.006359 = 6.359 E - 3.
 \end{aligned}$$

(49)

Para a barreira 2, seguindo a lógica do portão OR, semelhante ao evento C, os resultados encontrados foram:

$$P(\text{Barreira 2} = \text{Sucesso}) = 9.417E - 1$$

$$P(\text{Barreira 2} = \text{Falha}) = 5.823E - 2$$

Como a análise de *bowtie* define, as consequências do evento indesejado são calculadas por meio da técnica de uma árvore de evento, a partir da ocorrência do evento iniciador e das probabilidades de falha e sucesso das barreiras de segurança. Sendo assim, com a conversão da árvore de evento em rede bayesiana, a tabela de probabilidade condicional é definida semelhante ao evento C, como apresentado na Tabela 12 com a estrutura lógica e a Tabela 13 com os resultados. Para o cenário de ocorrência de sucesso do evento C, o estado das barreiras 1 e 2 são indiferentes, pois

elas não são acionadas quando o evento C não falha, como demonstrado na primeira linha das tabelas.

**Tabela 12:** Estrutura lógica da tabela de probabilidade condicional das consequências

Evento	Barreira 1	Barreira 2	Consequências				
			C <sub>0</sub>	C <sub>1</sub>	C <sub>2</sub>	C <sub>3</sub>	C <sub>4</sub>
$P(C = \text{Sucesso})$	$P(B1 = \text{Indiferente})$	$P(B2 = \text{Indiferente})$	$P(\text{Consequência} = C_0/C = \text{Indif., B1} = \text{Indif., B2} = \text{Indif.})$	$P(\text{Consequência} = C_1/C = \text{Indif., B1} = \text{Indif., B2} = \text{Indif.})$	$P(\text{Consequência} = C_2/C = \text{Indif., B1} = \text{Indif., B2} = \text{Indif.})$	$P(\text{Consequência} = C_3/C = \text{Indif., B1} = \text{Indif., B2} = \text{Indif.})$	$P(\text{Consequência} = C_4/C = \text{Indif., B1} = \text{Indif., B2} = \text{Indif.})$
$P(C = \text{Falha})$	$P(B1 = \text{Sucesso})$	$P(B2 = \text{Sucesso})$	$P(\text{Consequência} = C_0/C = \text{Falha, B1} = \text{Sucesso, B2} = \text{Sucesso})$	$P(\text{Consequência} = C_1/C = \text{Falha, B1} = \text{Sucesso, B2} = \text{Sucesso})$	$P(\text{Consequência} = C_2/C = \text{Falha, B1} = \text{Sucesso, B2} = \text{Sucesso})$	$P(\text{Consequência} = C_3/C = \text{Falha, B1} = \text{Sucesso, B2} = \text{Sucesso})$	$P(\text{Consequência} = C_4/C = \text{Falha, B1} = \text{Sucesso, B2} = \text{Sucesso})$
$P(C = \text{Falha})$	$P(B1 = \text{Sucesso})$	$P(B2 = \text{Falha})$	$P(\text{Consequência} = C_0/C = \text{Falha, B1} = \text{Sucesso, B2} = \text{Falha})$	$P(\text{Consequência} = C_1/C = \text{Falha, B1} = \text{Sucesso, B2} = \text{Falha})$	$P(\text{Consequência} = C_2/C = \text{Falha, B1} = \text{Sucesso, B2} = \text{Falha})$	$P(\text{Consequência} = C_3/C = \text{Falha, B1} = \text{Sucesso, B2} = \text{Falha})$	$P(\text{Consequência} = C_4/C = \text{Falha, B1} = \text{Sucesso, B2} = \text{Falha})$
$P(C = \text{Falha})$	$P(B1 = \text{Falha})$	$P(B2 = \text{Sucesso})$	$P(\text{Consequência} = C_0/C = \text{Falha, B1} = \text{Falha, B2} = \text{Sucesso})$	$P(\text{Consequência} = C_1/C = \text{Falha, B1} = \text{Falha, B2} = \text{Sucesso})$	$P(\text{Consequência} = C_2/C = \text{Falha, B1} = \text{Falha, B2} = \text{Sucesso})$	$P(\text{Consequência} = C_3/C = \text{Falha, B1} = \text{Falha, B2} = \text{Sucesso})$	$P(\text{Consequência} = C_4/C = \text{Falha, B1} = \text{Falha, B2} = \text{Sucesso})$
$P(C = \text{Falha})$	$P(B1 = \text{Falha})$	$P(B2 = \text{Falha})$	$P(\text{Consequência} = C_0/C = \text{Falha, B1} = \text{Falha, B2} = \text{Falha})$	$P(\text{Consequência} = C_1/C = \text{Falha, B1} = \text{Falha, B2} = \text{Falha})$	$P(\text{Consequência} = C_2/C = \text{Falha, B1} = \text{Falha, B2} = \text{Falha})$	$P(\text{Consequência} = C_3/C = \text{Falha, B1} = \text{Falha, B2} = \text{Falha})$	$P(\text{Consequência} = C_4/C = \text{Falha, B1} = \text{Falha, B2} = \text{Falha})$

Fonte: A autora (2023)

**Tabela 13:** Tabela de probabilidade condicional das consequências

Evento	Barreira 1	Barreira 2	Consequências				
			C <sub>0</sub>	C <sub>1</sub>	C <sub>2</sub>	C <sub>3</sub>	C <sub>4</sub>
Sucesso	Indiferente	Indiferente	1	0	0	0	0
Falha	Sucesso	Sucesso	0	1	0	0	0
Falha	Sucesso	Falha	0	0	1	0	0
Falha	Falha	Sucesso	0	0	0	1	0
Falha	Falha	Falha	0	0	0	0	1

Fonte: A autora (2023)

Os resultados gerados pela aplicação da rede bayesiana em todo o *bowtie* foram obtidos considerando o evento C e as barreiras de segurança, e usando como referências a tabela de probabilidade condicional e a equação 50. A probabilidade de ocorrência de C<sub>0</sub> corresponde ao valor da probabilidade de sucesso do evento C.

$$\begin{aligned}
P(\text{Consequência} = C_1) &= P(\text{Consequência} = C_1 / C = \text{Falha}, \\
&\quad B1 = \text{Sucesso}, B2 = \text{Sucesso}) * P(C = \text{Falha}, B1 \\
&\quad = \text{Sucesso e } B2 = \text{Sucesso}) + P(\text{Consequência} = C_1 / C \\
&\quad = \text{Falha}, B1 = \text{Sucesso}, B2 = \text{Falha}) * P(C = \text{Falha}, B1 \\
&\quad = \text{Sucesso e } B2 = \text{Falha}) + P(\text{Consequência} = C_1 / C = \text{Falha}, \\
&\quad B1 = \text{Falha}, B2 = \text{Sucesso}) * P(C = \text{Falha}, B1 = \text{Falha e } B2 \\
&\quad = \text{Sucesso}) + P(\text{Consequência} = C_1 / C = \text{Falha}, \\
&\quad B1 = \text{Falha}, B2 = \text{Falha}) * P(C = \text{Falha}, B1 = \text{Falha e } B2 \\
&\quad = \text{Falha})
\end{aligned}
\tag{50}$$

$$\begin{aligned}
P(\text{Consequência} = C_1) \\
&= 1 * (3.429E - 1) * (9.936E - 1) * (9.417E - 1) + 0 \\
&* (3.429E - 1) * (9.936E - 1) * (5.823E - 2) + 0 * (3.429E - 1) \\
&* (6.359E - 3) * (9.417E - 1) + 0 * (3.429E - 1) * (6.359E - 3) \\
&* (5.823E - 2) = 3.209E - 1
\end{aligned}$$

Para a consequência  $C_2$ :

$$\begin{aligned}
P(\text{Consequência} = C_2) \\
&= 0 * (3.429E - 1) * (9.936E - 1) * (9.417E - 1) + 1 \\
&* (3.429E - 1) * (9.936E - 1) * (5.823E - 2) + 0 * (3.429E - 1) \\
&* (6.359E - 3) * (9.417E - 1) + 0 * (3.429E - 1) * (6.359E - 3) \\
&* (5.823E - 2) = 1.985E - 2
\end{aligned}$$

Para a consequência  $C_3$ :

$$\begin{aligned}
P(\text{Consequência} = C_3) \\
&= 0 * (3.429E - 1) * (9.936E - 1) * (9.417E - 1) + 0 \\
&* (3.429E - 1) * (9.936E - 1) * (5.823E - 2) + 1 * (3.429E - 1) \\
&* (6.359E - 3) * (9.417E - 1) + 0 * (3.429E - 1) * (6.359E - 3) \\
&* (5.823E - 2) = 2.054E - 3
\end{aligned}$$

Para a consequência  $C_4$ :

$$\begin{aligned}
P(\text{Consequência} = C_4) = \\
&= 0 * (3.429E - 1) * (9.936E - 1) * (9.417E - 1) + 0 \\
&* (3.429E - 1) * (9.936E - 1) * (5.823E - 2) + 0 * (3.429E - 1) \\
&* (6.359E - 3) * (9.417E - 1) + 1 * (3.429E - 1) * (6.359E - 3) \\
&* (5.823E - 2) = 1.27E - 4
\end{aligned}$$

Sendo esses os resultados obtidos na primeira hipótese de aplicação, que serviram de comparação para as outras hipóteses. A conversão do caso em rede bayesiana permite que seja possível realizar não apenas o diagnóstico calculado por outras técnicas

como a árvore de falha, mais também o prognóstico do evento estudado. Com esse processo é possível atualizar os parâmetros utilizados.

### 2ª Hipótese

Na segunda hipótese, foram considerados aspectos dinâmicos no contexto da hipótese básica, em que todos os eventos, as barreiras e as consequências são avaliadas ao longo do tempo, tornando o *bowtie* dinâmico, apresentado na Figura 19. Para isso, a rede bayesiana estática foi convertida em dinâmica para o evento C e para as barreiras de segurança, gerando os valores para as consequências ao longo do tempo. Com essa finalidade, inicialmente, os eventos básicos são calculados para cada intervalo de tempo por meio da cadeia de Markov, que é caracterizado pelo conceito de que o evento do intervalo de tempo seguinte é influenciado apenas pelo evento do tempo anterior. Para o cálculo da probabilidade em cada estado é considerado que o evento estava no tempo T e foi para o tempo T +  $\Delta t$ . Sendo assim, as expressões que conduziram a estas probabilidades são dadas na Tabela 14. O evento estar no estado de sucesso visto que no tempo anterior estava no estado de sucesso, significa dizer que ele não falhou nesse intervalo, sendo assim representa a confiabilidade nesse intervalo de tempo. Entretanto, quando um evento está no estado de falha dado que ele estava no estado de sucesso no intervalo de tempo anterior, significa que houve a falha nesse intervalo de tempo. Como para esse exemplo foi considerado que houve um processo de inspeção/teste, em que identificou se o elemento está funcionando ou falho, entretanto quando o elemento foi verificado em estado falho, não houve a continuidade da operação do processo com o elemento, portanto a probabilidade de o evento estar no estado de sucesso visto que no intervalo anterior estava no estado de falha é zero. E a probabilidade de o evento estar falho considerando que no tempo anterior ele estava falho é 1. A Tabela 14 contém as relações condicionais dos componentes em cada estado para o intervalo de tempo T +  $\Delta t$ , considerando o processo de Markov.

**Tabela 14:** Probabilidades das relações de transição entre nós consecutivos

T	T + $\Delta t$	
	Sucesso	Falho
Sucesso	$P(\text{Sucesso}(t + \Delta t)   \text{Sucesso}(t))$	$P(\text{Falho}(t + \Delta t)   \text{Sucesso}(t))$
Falha	$P(\text{Sucesso}(t + \Delta t)   \text{Falho}(t))$	$P(\text{Falho}(t + \Delta t)   \text{Falho}(t))$

**Fonte:** Adaptada pela autora a partir de Cai *et. al* (2013a)

Diante disso, para identificar as probabilidades de cada evento se encontrar em um dos possíveis estados, deve-se considerar as probabilidades dadas pelas expressões abaixo:

$$\begin{aligned}
 P(\text{Sucesso}(t + \Delta t)) &= P(\text{Sucesso}(t + \Delta t) | \text{Sucesso}(t)) * P(\text{Sucesso}(t)) \\
 &+ P(\text{Sucesso}(t + \Delta t) | \text{Falha}(t)) * P(\text{Falha}(t))
 \end{aligned}
 \tag{51}$$

E para a probabilidade de falha:

$$\begin{aligned}
 P(\text{Falho}(t + \Delta t)) &= P(\text{Falho}(t + \Delta t) | \text{Sucesso}(t)) * P(\text{Sucesso}(t)) \\
 &+ P(\text{Falho}(t + \Delta t) | \text{Falha}(t)) * P(\text{Falha}(t))
 \end{aligned}$$

Portanto, a probabilidade de falha de um evento em um determinado tempo é a probabilidade de o evento estar no estado de falha dado que no intervalo anterior ele estava no estado de sucesso, multiplicado pela probabilidade de ele ter se encontrado no estado de sucesso no intervalo anterior, somado pela probabilidade de estar no estado falho dado que no tempo anterior ele estava no estado falho, multiplicado pela probabilidade de estar falho no intervalo de tempo anterior. Por exemplo, a probabilidade de um evento estar no estado falho no tempo  $T=800$  h é preciso considerar a probabilidade de sucesso e de falha no intervalo de tempo anterior,  $T=400$  h, sendo assim:

$$\begin{aligned}
 P(\text{Falho}(t = 800)) &= P(\text{Falho}(t = 800) | \text{Sucesso}(t = 400)) * P(\text{Sucesso}(t = 400)) \\
 &+ P(\text{Falho}(t = 800) | \text{Falha}(t = 400)) * P(\text{Falha}(t = 400))
 \end{aligned}$$

Portanto, uma fórmula genérica, para esse caso sem reparo, pode ser dada por:

$$P(\text{Falha}(t + \Delta t)) = F(\Delta t) * R(t) + F(t)
 \tag{52}$$

Essa expressão genérica mostra que para quaisquer intervalos de tempo, a probabilidade de falha no tempo seguinte analisado é a probabilidade de falha no intervalo de tempo  $\Delta t$  multiplicado pela confiabilidade no tempo  $t$  somando a probabilidade de falha no tempo  $t$ . Para o caso hipotético, a confiabilidade e a probabilidade de falha descrita para o intervalo considerando que o evento possui uma

taxa constante, ou seja, é representada por uma distribuição exponencial. Contudo, essas fórmulas são modificadas dependendo da distribuição a ser aplicada no evento.

Para o caso desse estudo, considerando as probabilidades representadas por uma distribuição exponencial, as expressões são dadas por:

$$P(\text{Sucesso}(t + \Delta t)) = ((e^{-\lambda \Delta t}) * (e^{-\lambda t})) + (0) * (1 - e^{-\lambda t}) = ((e^{-\lambda \Delta t}) * (e^{-\lambda t})) \quad (53)$$

E para a probabilidade de falha:

$$P(\text{Falho}(t + \Delta t)) = (1 - e^{-\lambda \Delta t}) * (e^{-\lambda t}) + 1 * (1 - e^{-\lambda t}) \quad (54)$$

Como mencionado anteriormente, para o processo dinâmico é considerado a ocorrência de uma inspeção/teste em cada intervalo de tempo, o que indica se o evento ocorreu ou não. Essa inspeção/teste possui uma condição de medição incompleta, ou seja, há casos em que no processo de inspeção é detectado que o evento está em estado de sucesso, entretanto ele se encontra falho. A probabilidade desse erro da inspeção ocorrer varia dependendo da inspeção e do componente avaliado, nomeado como  $w$ . Que é o mesmo que mencionado anteriormente como o PTC (*proof test coverage*), presente na equação 22. Para esse caso hipotético, a inspeção/teste é realizada para identificar se o evento C e as falhas das barreiras ocorreram ou não, sendo a probabilidade assumida como 20%, sendo esse o valor de  $w$ . É assumido também que quando o teste detecta uma falha, o componente associado ao evento sempre vai para reparo e não retorna para a operação, o que está representado pela segunda coluna na Tabela 15. A tabela de probabilidade condicional associada a essa condição de inspeção/teste incompleto encontra-se na Tabela 15.

**Tabela 15:** Relações de transição entre nós consecutivos para uma inspeção incompleta.

T	Inspeção/Teste Incompleto	
	Detecta Não Falha	Detecta Falha
Sucesso	$(1 - w)$	0
Falha	$w$	1

Fonte: A autora(2023)

Portanto, o cálculo para a probabilidade de falha para o tempo do teste ( $t$ ) segue a seguinte equação:

$$P(\text{Falha}(t)) = w * P(\text{Falha}(\Delta t)) \quad (55)$$

Em que  $\Delta t$  é o intervalo de tempo entre os testes e  $w$  é a probabilidade de erro na detecção de falha da inspeção. A probabilidade de falha após o teste ( $t^+$ ) segue a estrutura mencionada na equação 55, dada por:

$$P(\text{Falho}(t^+)) = w * (P(\text{Falho}(t^+) | \text{Sucesso}(t-1)) * P(\text{Sucesso}(t-1)) + P(\text{Falho}(t^+) | \text{Falha}(t-1)) * P(\text{Falho}(t-1))) \quad (56)$$

Em que a  $P(\text{Falho}(t^+) | \text{Falha}(t-1))$  possui valor igual a 1, visto que o teste não detectou essa falha e o componente está falho, então essa falha se perpetua até o intervalo de tempo seguinte. Portanto, semelhante a equação 51 e utilizando a equação 55, a equação que representa a probabilidade de falha do componente/evento após o teste é dada por:

$$P(\text{Falha}(t^+)) = w * (P(\text{Falha}(\Delta t)) * P(\text{Sucesso}(t-1)) + 1 * P(\text{Falha}(t-1))) \quad (57)$$

Para o caso hipotético, essa equação acima é solucionada inicialmente pelo cálculo da probabilidade dos eventos A e B no primeiro intervalo de tempo ( $T=400$  h), conhecido como *time-slice*. Como esses eventos são representados por uma distribuição exponencial, então os valores das probabilidades de sucesso e falha do evento A para o primeiro intervalo são dados pela equação 48 para identificar a probabilidade de falha no tempo  $T=400$  antes da inspeção:

$$P(\text{Falho A}(t=400)) = (1 - e^{-\lambda \Delta t}) * (e^{-\lambda(t-1)}) + 1 * (1 - e^{-\lambda(t-1)})$$

$$P(\text{Falho A}(t=400)) = (1 - e^{-(1e-4*400)}) * (e^{-1e-4*0}) + 1 * (1 - e^{-1e-4*0})$$

$$P(\text{Falho A}(t=400)) = (1 - e^{-(1e-4*400)}) = 3.921 E - 2$$

E baseado na equação 57 com uma inspeção com  $w=20\%$ , a probabilidade de falha após o teste é:

$$P(\text{Falho A}(t^+ = 400)) = w * P(\text{Falha}(t = 400))$$

$$P(\text{Falho A}(t^+ = 400)) = w * P(\text{Falha}(\Delta t)) = 20\% * (1 - e^{-(1e-4*400)})$$

$$= 0.2 * 3.921 E - 2 = 7.842 E - 3$$

E, a confiabilidade de:

$$P(\text{Sucesso } A (t^+ = 400)) = 1 - P(\text{Falha } A (t^-)) = 1 - 7.842E - 3 = 9.922 E - 1$$

Com isso, a partir da equação 57, e considerando um intervalo de  $\Delta t = 400$  horas, sendo  $t = 400$  h e  $t + \Delta t = 800$  h, e que com o teste não há retorno a operação em caso de falha, a probabilidade do estado de falha para o intervalo de  $t = 800$  h, os resultados encontrados para o evento A foram:

$$\begin{aligned} P(\text{Falha } A (t^+ = 800)) &= (P(\text{Falha } A (\Delta t = 400)) \\ &\quad * P(\text{Sucesso } A (t^+ = 400) + 1 * P(\text{Falha } (t^+ = 400))) * w \\ &= (3.921 E - 2 * 9.922 E - 1 + 1 * 7.842 E - 3) * 20\% = 9.349 E - 3 \end{aligned}$$

E

$$\begin{aligned} P(\text{Sucesso } A (t^+ = 800)) &= 1 - P(\text{Falha } A (t^+ = 800)) = 1 - 9.349 E - 3 \\ &= 9.907 E - 1 \end{aligned}$$

Para esse estudo foi considerado 4 intervalos de tempo, com 3 *time-slices*, em que o primeiro tempo é o  $T_0 = 0$ , em que a probabilidade de falha do Evento C é dada como zero e a confiabilidade como 1, e os próximos tempos foram  $T_1 = 400$  h,  $T_2 = 800$  h e  $T_3 = 1200$  h.

Os valores da probabilidade de falha e de sucesso para  $T_3 = 1200$  h considerando que esse é o tempo de missão e não há o teste ocorrendo nesse tempo, utilizando a equação 51, são:

$$\begin{aligned} P(\text{Falha } A (t = 1200)) &= P(\text{Falha } A (\Delta t = 400)) * P(\text{Sucesso } A (t^+ = 800)) \\ &\quad + P(\text{Falha } (t^+ = 800)) = 3.921 E - 2 * 9.907E - 1 + 9.349 E - 3 \\ &= 4.819 E - 2 \end{aligned}$$

E

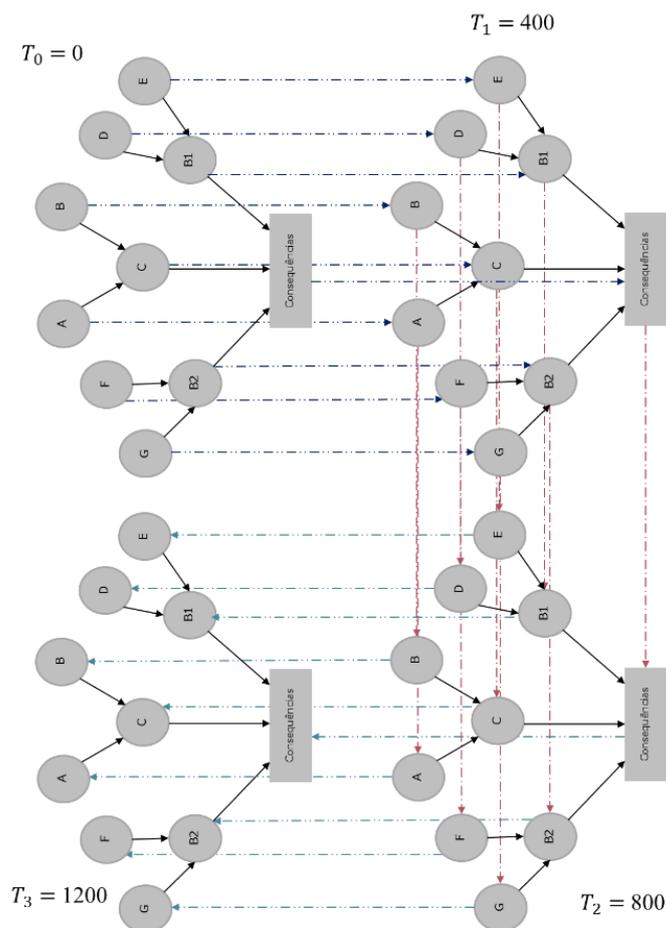
$$\begin{aligned} P(\text{Sucesso } A (t = 1200)) &= 1 - P(\text{Falha } A (t = 1200)) = 1 - 4.819 E - 2 \\ &= 9.518 E - 1 \end{aligned}$$

Portanto, a partir dessas equações é possível calcular as probabilidades do evento se encontrar em cada estado dado o intervalo de tempo escolhido. É importante lembrar que, para se calcular a probabilidade de cada evento estar em cada um dos possíveis estados ao final do primeiro intervalo, deve-se considerar que no início todos os eventos

encontram-se no estado de sucesso. O mesmo procedimento foi repetido para os eventos B, D, E, F e G.

Portanto, para os eventos básicos do evento C, das barreiras 1 e 2, as probabilidades dos estados para o primeiro, segundo e terceiro *time-slices* estão apresentados na Tabela 16.

**Figura 19:** Estrutura da rede bayesiana dinâmica para o caso hipotético



Fonte: A autora (2023)

**Tabela 16:** Valores de probabilidade dos eventos em cada *time-slice*

Eventos	<i>Time-slice 1</i>		<i>Time-slice 2</i>		<i>Time-slice 3</i>	
	P(Sucesso)	P(Falha)	P(Sucesso)	P(Falha)	P(Sucesso)	P(Falha)
Evento A	9.922E-01	7.842E-03	9.907E-01	9.349E-03	9.518E-01	4.819E-02
Evento B	9.810E-01	1.903E-02	9.775E-01	2.248E-02	8.845E-01	1.155E-01
Evento D	9.953E-01	4.743E-03	9.943E-01	5.669E-03	9.708E-01	2.925E-02
Evento E	9.937E-01	6.299E-03	9.925E-01	7.519E-03	9.612E-01	3.878E-02
Evento F	9.984E-01	1.594E-03	9.981E-01	1.910E-03	9.901E-01	9.863E-03
Evento G	9.976E-01	2.386E-03	9.971E-01	2.857E-03	9.852E-01	1.475E-02

Fonte: A autora (2023)

O cálculo do evento C e das barreiras de segurança são gerados semelhante ao caso 1, pelo método de rede bayesiana, a partir da tabela de probabilidade condicional e do teorema de *Bayes*. Os valores do evento C, das barreiras de segurança e das consequências obtidos nesse caso estão apresentados na Tabela 17.

**Tabela 17:** Probabilidades do evento C, das barreiras de segurança e das consequências em cada *time-slice*

Eventos	<i>Time-slice 1</i>		<i>Time-slice 2</i>		<i>Time-slice 3</i>	
	P(Sucesso)	P(Falha)	P(Sucesso)	P(Falha)	P(Sucesso)	P(Falha)
Evento C	9.7327E-01	2.6725E-02	9.6838E-01	3.1616E-02	8.4187E-01	1.5813E-01
Barreira 1	9.9997E-01	2.9874E-05	9.9996E-01	4.2623E-05	9.9887E-01	1.1341E-03
Barreira 2	9.9602E-01	3.9755E-03	9.9524E-01	4.7614E-03	9.7553E-01	2.4468E-02
Consequências	<i>Time-slice 1</i>		<i>Time-slice 2</i>		<i>Time-slice 3</i>	
Conseq. C <sub>0</sub>	9.7327E-01		9.6838E-01		8.4187E-01	
Conseq. C <sub>1</sub>	2.66183E-02		3.1464E-02		1.54083E-01	
Conseq. C <sub>2</sub>	1.06243E-04		1.5053E-04		3.86474E-03	
Conseq. C <sub>3</sub>	7.95213E-07		1.3412E-06		1.74949E-04	
Conseq. C <sub>4</sub>	3.17397E-09		6.4164E-09		4.38811E-06	

Fonte: A autora (2023)

Ao adicionar a estrutura dinâmica ao processo de análise é possível avaliar e verificar as probabilidades de ocorrência das consequências, dos eventos e das barreiras ao longo do tempo. Isso permite que seja possível tomar algumas decisões de planejamento e ações em caso de diminuição da confiabilidade.

### 3ª Hipótese

A terceira hipótese consiste em tratamento da incerteza nos valores das taxas de falha dos eventos para a rede bayesiana estática. Essa incerteza é inserida ao processo, visto que os dados de falha são escassos e oriundos de fontes não homogêneas. Uma das técnicas existentes utilizada para esse tipo de análise é o modelo bayesiana hierárquico que se baseia em inferência bayesiana para estimar as probabilidades de um cenário nessas condições.

A fim de gerar os valores *a posteriori* das probabilidades de ocorrência das consequências, considerando esse modelo hierárquico, foi associado ao evento C, as barreiras de segurança e as consequências, as ocorrências da falha em N demandas dos eventos, chamados de dados de alto nível. Com fins ilustrativo, foi proposto que o evento C, e as barreiras estudadas tenham sido demandadas 20 vezes, e o evento ocorreu apenas 4 vezes, enquanto a barreira 1 falhou 2 vezes e a barreira 2, uma vez. E para as

consequências, a demanda foi a mesma, entretanto, a consequência 1 ocorreu 2 vezes, a consequência 2, não ocorreu, e a terceira e quarta consequências aconteceram apenas 1 vez. Com isso, seguindo uma adaptação de Yu *et al.* (2017), a ocorrência da falha do evento C e das barreiras de segurança, foram modelados por uma distribuição binomial com  $N = 20$  demandas e  $n = 4$  falhas, seguindo a lógica da probabilidade de falha apresentada na equação abaixo. Assim como para as consequências  $N= 20$  e  $n_1=2$ ,  $n_2 = 0$ ,  $n_3=1$  e  $n_4 = 1$ , apresentadas na Tabela 18, para o tempo  $T=1200$  h. Para esse caso não é considerado nenhuma inspeção/teste e por isso o valor de  $w$  não é utilizado.

$$P(\text{Falha}) = \binom{N}{n} P(\text{Evento C} = \text{Falho})^n (1 - P(\text{Evento C} = \text{Falho}))^{N-n} \quad (58)$$

**Tabela 18:** Informações de evidências dos eventos

T = 1200 h		
Eventos	Demanda (n)	Ocorrências (x)
Evento C	20 demandas	4 falhas
Barreira 1	20 demandas	2 falhas
Barreira 2	20 demandas	1 falha
Consequência C <sub>1</sub>	20 demandas	2 falhas
Consequência C <sub>2</sub>	20 demandas	0 falhas
Consequência C <sub>3</sub>	20 demandas	1 falha
Consequência C <sub>4</sub>	20 demandas	1 falha

**Fonte:** A autora (2023)

As informações dos dados de alto nível no código utilizado são representados como “x.C” e “n.EventoC”, sendo respectivamente o número de falhas e as demandas; e representado pela distribuição binomial, como apresentado na primeira linha do código apresentado abaixo. A probabilidade de falha do evento C é dada por “p.EventoC”, que contém a relação entre o parâmetro de interesse e os dados de alto nível.

*# Distribuição binomial com os dados de alto nível*

x.C ~ dbin(p.EventoC, n.EventoC)

Além das informações de alto nível, foram consideradas as opiniões de especialistas como dados sobre os eventos básicos do evento C e das barreiras de segurança. Portanto, esse caso consiste em estimar a probabilidade de ocorrência das consequências a partir de um evento iniciador e das barreiras de segurança, por meio dos seus eventos básicos com dados oriundos da opinião de especialista e sua incerteza

considerando os dados de alto nível. Os valores dos parâmetros de interesse são as taxas de falha do evento C e das barreiras que foram geradas a partir da modelagem via rede bayesiana estática e através do modelo bayesiano hierárquico conforme apresentado por Droguett *et al.* (2004 e 2006). Os hiperparâmetros possuem uma distribuição *a priori* definida por uma distribuição lognormal, com a variabilidade da opinião de especialistas também caracterizada por uma lognormal, conforme proposto pelos estudos de Droguett *et al.* (2004); Martino (1970); Mosleh e Apostolakis (1986); Cookie (1991) e Mosleh (1992). As variações dos hiperparâmetros também são dadas por lognormais bem difusas. Para o cálculo dessa inferência será utilizado o software WinBUGS (WINBUGS, 2007).

O código utilizado para a estimativa da probabilidade do evento iniciador (Evento C) é apresentado abaixo contendo a estimativa de 5 especialistas. O evento C é gerado pela combinação dos eventos básicos A e B, apresentada na penúltima linha do código. A opinião dos especialistas foi utilizada para cada evento básico. Em que os hiperparâmetros de cada opinião são definidos por distribuições lognormais apresentada na equação 39 e 40 presentes na fundamentação.

```
for (i in 1: N) #Determinação da verossimilhança para os especialistas
{
op.A[i] ~ dlnorm (um.A, tau.op.A[i]) #Variabilidade dos especialistas dada por uma
distribuição lognormal para a taxa de falha de A

tau.op.A[i] <- 1/pow(log(ef.A[i]) /1.645, 2) #Determinação de tau a partir do fator de erro de
cada especialista sobre a taxa de falha de A
}

for ( j in 1: M)
{
op.B[j] ~ dlnorm (um.B, tau.op.B[j]) #Variabilidade dos especialistas dada por uma
distribuição lognormal para a taxa de falha de B

tau.op.B[j] <- 1/pow(log(ef.B[j]) /1.645, 2)#Determinação de tau a partir do fator de erro de
cada especialista sobre a taxa de falha de B
```

A distribuição *a priori* do parâmetro de interesse é dada por uma distribuição lognormal da taxa de falha que possui os parâmetros representados por “mu.A” e “tau.A”, por exemplo para o evento A, presente na nona linha do código, apresentado acima. As *hiperprioris* do parâmetro de interesse são representadas por “priori.ef.A” e “priori.medianaA”. A “priori.medianaA” é representada por uma distribuição lognormal, em que os parâmetros da média e da variância são obtidos por meio de

banco de dados genéricos que serviram de base para gerar uma mediana para essa taxa de falha. Como exemplo, para o evento A, foi identificado que a taxa de falha utilizada é de  $1E-4$ , portanto esse valor será utilizado como *priori* da mediana para o cálculo da taxa de falha. Como é usado uma distribuição lognormal, então o valor a ser acrescentado no código do Winbugs na média dessa distribuição precisa ser o logaritmo neperiano desse valor, sendo assim, o valor a ser acrescentado no hiperparâmetro “*priori.medianaA*” será de -9.21. Isso precisou ser realizado anteriormente, pois o código somente recebe esse valor e não realiza a conversão para o neperiano.

O fator de erro representa o grau de relevância da opinião, quanto maior for esse fator menor é a sua relevância, representado por “*priori.ef.A*”. O fator de erro é representado por uma distribuição lognormal, portanto, o fator de erro representa a largura da distribuição lognormal, e portanto, fornece a incerteza, em que, um fator de erro alto implica maior incerteza associada ao resultado (HAVIARAS, 2005). Esse erro é adicionado no desvio padrão da distribuição lognormal da opinião de especialista, visto que considera o grau de dispersão da opinião de especialista, e assim incluindo a incerteza das opiniões.

Os processos de integração para essa modelagem bayesiana hierárquica ocorrem via geração de cadeias de Markov, por meio de simulações de Monte Carlo (MCMC – Monte Carlo Markov Chain) (DROGUETT *et al.*, 2004). Sendo as integrais presentes nas equações 28, 29 e 30 calculadas. O código relacionado a essa integração está apresentado abaixo, referente ao evento A.

```
lamb.EventoA ~dlnorm (um.A, tau.A) #Densidade predita para taxa de falha
tau.A <- pow(log(priori.ef.A)/1.645, -2)
priori.ef.A ~ dlnorm(5, 5) # Hiperpriori para o fator de erro
um.A <- log(priori.medianaA1)
priori.medianaA ~ dlnorm(-9.21, 0.5) #Hiperpriori para a mediana
p.EventoA <- (1 - exp(- lamb.EventoA1*T1)) # probabilidade de falha do evento A1
```

No segundo momento, é realizado cálculo das barreiras de segurança, que é semelhante ao do evento iniciador, como apresentado pelo código abaixo para a barreira B1. O mesmo processo foi feito para a barreira B2.

```
#Barreira B1
```

```
# Distribuição binomial com os dados de alto nível
x.Barreira1 ~ dbin(p.Barreira1, n.Barreira1)
```

```
for (k in 1: P) #Determinação da verossimilhança para os especialistas
{
```

```

op.D1[k] ~ dlnorm(mu.Barreira.D1, tau.op.D1[k]) #Variabilidade dos especialistas dada por
uma distribuição lognormal para a taxa de falha do evento básico D da barreira B1 no tempo
T1

tau.op.D1[k] <- 1/pow(log(ef.D1[k]) /1.645, 2) #Determinação de tau a partir do fator de erro
de cada especialista sobre a taxa de falha do evento básico D da barreira B1 no tempo T1

}
lamb.BarreiraD1 ~ dlnorm(mu.Barreira.D1, tau.Barreira.D1) #Densidade predita para taxa de
falha do evento D
tau.Barreira.D1 <- pow(log(priori.ef.BarreiraD1)/1.645, -2)
priori.ef.BarreiraD1 ~ dlnorm(5, 5) # Hiperpriori para o fator de erro
mu.Barreira.D1 <- log(priori.mediana.BarreiraD1)
priori.mediana.BarreiraD1 ~ dlnorm(-9.72, 0.6) #Hiperpriori para a mediana
p.BarreiraD1 <- 1 - exp(- lamb.BarreiraD1*T1) # probabilidade de falha do evento D no tempo
T1

```

Após o cálculo do evento iniciador e das barreiras de segurança, o próximo passo é modelar o código para o cálculo das probabilidades de ocorrência das consequências. Baseados no método de árvore de evento convertido em rede bayesiana, apresentado na primeira hipótese, o código para essa parte da modelagem apresenta a seguinte estrutura, em que contém os dados de alto nível para cada consequência e as probabilidades de ocorrência de cada consequência a partir do sucesso e da falha das barreiras de segurança.

```

# Distribuição Binomial dos dados de alto nível
x.Conseq1 ~ dbin(p.Conseq1, n.Conseq1)
x.Conseq2 ~ dbin(p.Conseq2, n.Conseq2)
x.Conseq3 ~ dbin(p.Conseq3, n.Conseq3)
x.Conseq4 ~ dbin(p.Conseq4, n.Conseq4)

# Cálculo das Consequências
p.Conseq1 <- p.EventoC * (1 - p.Barreira1) * (1 - p.Barreira2)
p.Conseq2 <- p.EventoC * (1 - p.Barreira1) * (p.Barreira2)
p.Conseq3 <- p.EventoC * (p.Barreira1) * (1 - p.Barreira2)
p.Conseq4 <- p.EventoC * (p.Barreira1) * (p.Barreira2)

```

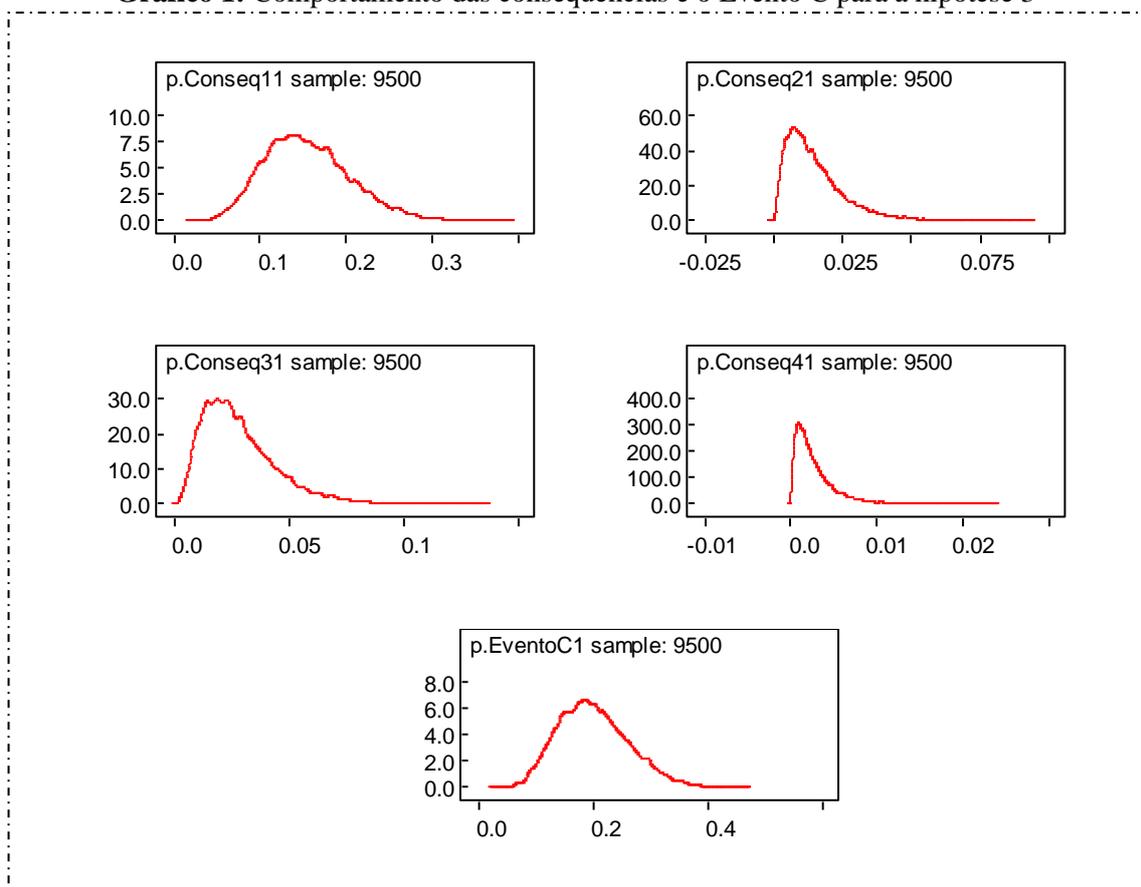
Após as interações no Winbugs, as probabilidades do estado de falha para os eventos A, B, C, D, E, F e G, das barreiras de segurança e das consequências estão apresentados na Tabela 19, para um tempo de T=1200 horas, para fins comparativos. Esses resultados foram obtidos a partir da aplicação de Monte Carlo com 10.000 interações, a fim de se obter resultados mais precisos. A confiança utilizada para gerar esses valores foi de 5% e 95%, com objetivo de realizar comparações entre os casos com incerteza. A confiança de 95% significa há 95% de confiança que a confiabilidade seja superior a esse valor. Assim como para 5% significa que o valor a confiabilidade

seja inferior a esse valor. Esse código se encontra no apêndice 3 desse trabalho. O Gráfico 1 contém os comportamentos das consequências para esse caso.

**Tabela 19:** Valores das probabilidades de Falha de A, B e C, das barreiras de segurança e das consequências para a hipótese 3

Eventos Finais				
Tempo T = 1200	Média	Sd	5%	95%
Evento C	2.007E-1	6.177E-2	1.093E-1	3.099E-1
Barreira 1	1.539E-1	7.041E-2	5.605E-2	2.849E-1
Barreira 2	8.758E-2	5.404E-2	2.092E-2	1.910E-1
Consequências				
Tempo T = 1200	Média	Sd	5%	95%
Consequência C <sub>1</sub>	1.548E-1	4.995E-2	8.180E-2	2.434E-1
Consequência C <sub>2</sub>	1.494E-2	1.084E-2	2.974E-3	3.629E-2
Consequência C <sub>3</sub>	2.821E-1	1.620E-2	8.406E-3	5.961E-2
Consequência C <sub>4</sub>	2.722E-3	2.478E-3	3.705E-4	7.555E-3

**Gráfico 1:** Comportamento das consequências e o Evento C para a hipótese 3



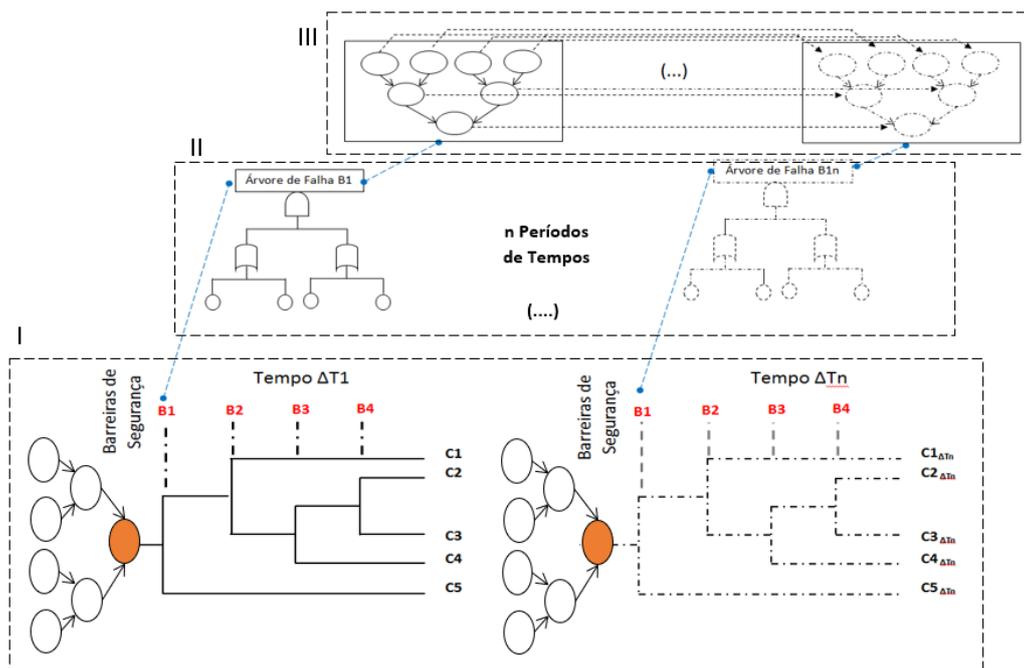
**Fonte:** A autora (2023)

O uso da rede bayesiana como metodologia aplicada a esse processo permite a possibilidade de tratar a incerteza aos eventos e propagá-la, em colaboração com a

modelagem bayesiana hierárquica. O uso dessa modelagem permitiu que fosse possível utilizar a opinião de especialistas e dados de alto nível para atualização dos eventos, das consequências e das barreiras de segurança. Por isso, a rede bayesiana foi escolhida como a mais adequada para esse estudo.

#### *4ª Hipótese*

A quarta hipótese de aplicação adiciona a dinâmica à etapa anterior, com a propagação da incerteza nos intervalos de tempo. Essa etapa consiste no processo metodológico proposto nesse estudo, com a estrutura do *bowtie* dinâmico. A Figura 20 apresenta a representação gráfica dessa proposta, em que à esquerda se encontra a rede bayesiana dinâmica do evento iniciador (indesejado), e à direita, a árvore de evento, caracterizando assim a estrutura do *bowtie*. Nessa Figura 20, à esquerda do elemento I se encontra um *bowtie* para um determinado tempo  $\Delta T_1$ , em que estão contidas o evento iniciador e as barreiras de segurança que podem ser representadas por uma árvore de falha, apresentada pelo elemento II. No elemento I, as redes bayesianas do evento iniciador são dinâmicas. Para que o caso possa ser representado de forma dinâmica, essas árvores serão convertidas em rede bayesiana dinâmica, visto pelo elemento III. Para que haja uma dinâmica do *bowtie*, todos esses itens foram progredidos ao longo do tempo, até um período  $\Delta T_n$ . Para esse cálculo foi considerado inferência bayesiana por meio do modelo bayesiana hierárquico aplicado a rede bayesiana dinâmica. Por meio desse processo foi possível obter resultados referentes as taxas de falha atualizadas com propagação de incerteza para cada barreira de segurança, para o evento iniciador, assim como para as probabilidades de ocorrência das consequências ( $C_1, C_2, \dots, C_5$ ).

**Figura 20:** Representação Gráfica do processo metodológico

Fonte: A autora (2023)

Os eventos básicos são estimados semelhante ao caso anterior, com o apoio do modelo bayesiano hierárquico a partir de opinião de especialistas e dados de alto nível. Entretanto ao adicionar a variação ao longo do tempo, semelhante ao caso 2, é utilizada a cadeia de Markov para o estudo dinâmico. Para essa condição, a inspeção/teste incompleto do sistema vai ocorrer ao final do tempo  $T=1200$  h, em que  $w=20\%$  é considerado tanto para os componentes do evento iniciador quanto das barreiras.

A modelagem adicionada ao código para o segundo e terceiro *time-slices* para o evento A é dado por:

*#Segundo time-slice*

$$p.\text{EventoA2} <- ((p.\text{EventoA1}) * (1 - p.\text{EventoA1} * w) + p.\text{EventoA1} * w) * w$$

*#Terceiro time-slice*

$$p.\text{EventoA3} <- (p.\text{EventoA1}) * (1 - p.\text{EventoA2}) + p.\text{EventoA2}$$

Para o cálculo do segundo *time-slice* é dada pela equação 52, em que a probabilidade de falha nesse intervalo de tempo é a probabilidade de falha no intervalo de tempo entre o primeiro e o segundo *time-slice* multiplicado pela confiabilidade no intervalo anterior, somando pela probabilidade de falha no intervalo de tempo anterior. E tudo multiplicado pelo erro da inspeção. Como os intervalos de tempo são os mesmos, então a probabilidade de falha do intervalo é sempre o mesmo entre o  $T_0$  e  $T_1$ ,

por isso, é calculado por “p.EventoA1”. Enquanto para o terceiro intervalo de tempo, a confiabilidade do intervalo anterior é referente a confiabilidade no segundo *time-slice*.

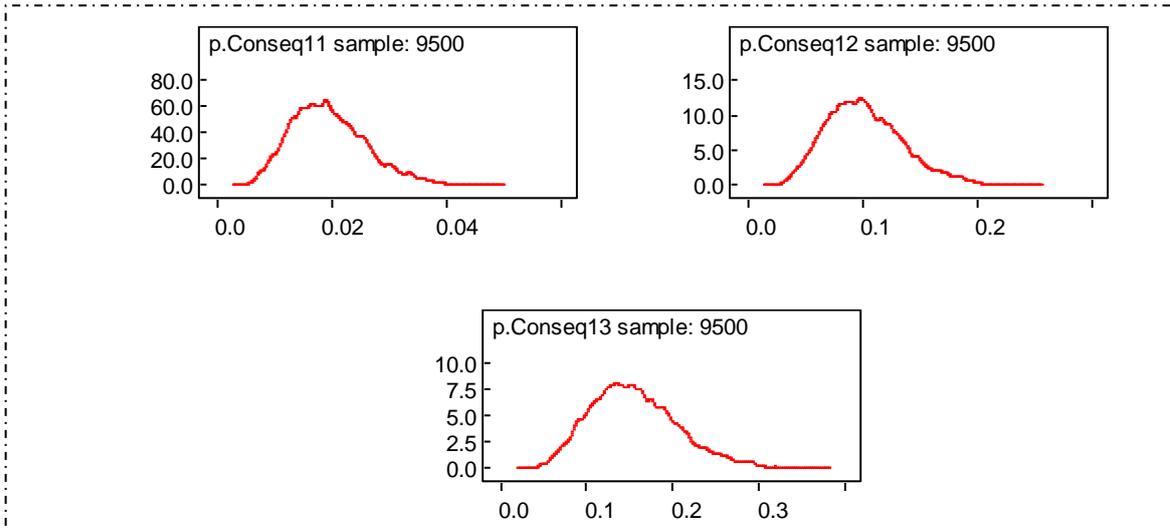
Os dados de alto nível para as barreiras de segurança, do evento indesejado e das consequências são adicionados ao processo dinâmico para o último intervalo de tempo, na forma de distribuição binomial como apresentado no caso anterior (Hipótese 3).

O mesmo processo de estimativa das probabilidades dos eventos básicos para os tempos seguintes é aplicado para as barreiras de segurança. O cálculo das consequências para os eventos em cada intervalo de tempo é idêntico ao código apresentado no caso anterior. A Tabela 20 apresenta todos os resultados obtidos pela modelagem do quarto caso para os eventos básicos, para as barreiras de segurança e para as consequências para fins de comparação com os casos anteriores. O Gráfico 2 contém os gráficos das consequências ao longo do tempo. Os resultados da confiabilidade são medidos para o 95% percentil, ou seja, há 95% de confiança que a confiabilidade seja superior a esse valor. Esse código completo se encontra no apêndice 4 desse trabalho. O apêndice 3 contém o código utilizado nesse caso de aplicação.

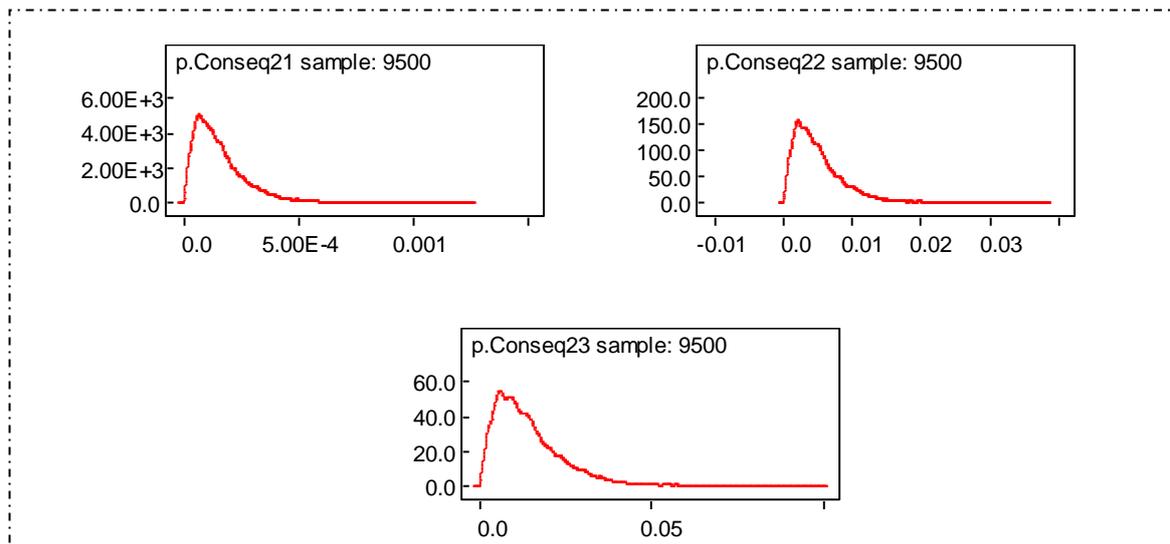
**Tabela 20:** Resultados obtidos na aplicação da hipótese 4

<b>Tempo T = 400</b>	<b>Média</b>	<b>Sd</b>	<b>5%</b>	<b>95%</b>
Evento C	1.972E-2	6.632E-3	1.003E-2	3.182E-2
Barreira 1	2.279E-3	1.331E-3	6.364E-4	4.854E-3
Barreira 2	8.22E-3	5.417E-3	1.813E-3	1.871E-2
Consequência C <sub>1</sub>	1.95E-2	6.558E-3	8.72E-3	3.149E-2
Consequência C <sub>2</sub>	1.623E-4	1.27E-4	2.887E-5	1.296E-4
Consequência C <sub>3</sub>	4.468E-5	3.164E-5	1.020E-5	1.074E-4
Consequência C <sub>4</sub>	3.692E-7	3.914E-7	3.936E-8	1.117E-6
<b>Tempo T = 800</b>	<b>Média</b>	<b>Sd</b>	<b>5%</b>	<b>95%</b>
Evento C	1.152E-1	3.778E-2	5.945E-2	1.843E-1
Barreira 1	7.087E-2	3.90E-2	2.113E-2	1.462E-1
Barreira 2	4.867E-2	3.167E-2	1.086E-2	1.101E-1
Consequência C <sub>1</sub>	1.018E-1	3.366E-2	5.221E-2	1.640E-1
Consequência C <sub>2</sub>	5.23E-3	4.034E-3	9.483E-4	1.297E-2
Consequência C <sub>3</sub>	7.79E-3	5.24E-3	1.888E-3	1.804E-2
Consequência C <sub>4</sub>	3.974E-4	4.056E-4	4.544E-5	1.188E-3
<b>Tempo T = 1200</b>	<b>Média</b>	<b>Sd</b>	<b>5%</b>	<b>95%</b>
Evento C	2.003E-1	6.223E-2	1.064E-1	3.128E-1
Barreira 1	1.527E-1	7.113E-2	5.372E-2	2.842E-1
Barreira 2	8.676E-2	5.485E-2	1.982E-2	1.929E-1
Consequência C <sub>1</sub>	1.549E-1	5.031E-2	8.059E-2	2.468E-1
Consequência C <sub>2</sub>	1.478E-2	1.106E-2	2.763E-3	3.576E-2
Consequência C <sub>3</sub>	2.802E-2	1.648E-2	7.939E-3	5.952E-2
Consequência C <sub>4</sub>	2.657E-3	2.475E-3	3.603E-4	7.511E-3

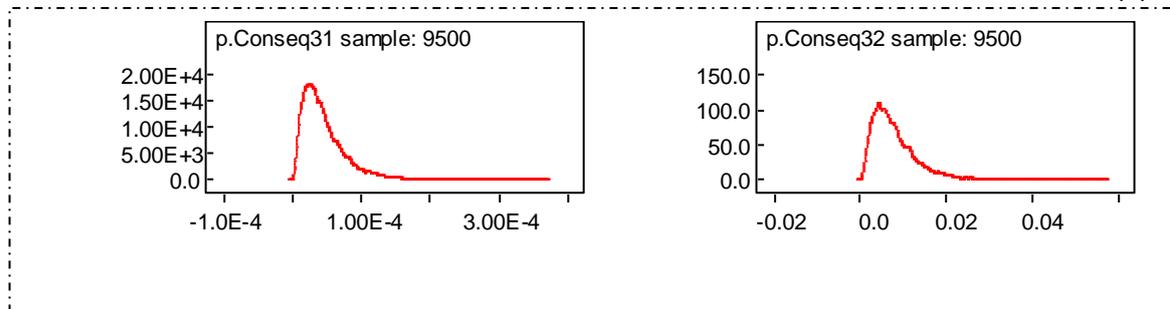
**Gráfico 2:** Comportamento das consequências e o evento C ao longo dos intervalos e (a) Consequência 1, (b) Consequência 2, (c) Consequência 3, (d) Consequência 4 e Evento C (e)

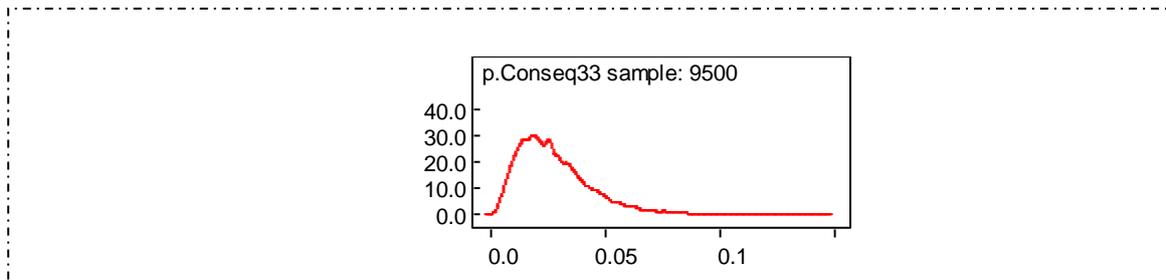


(a)

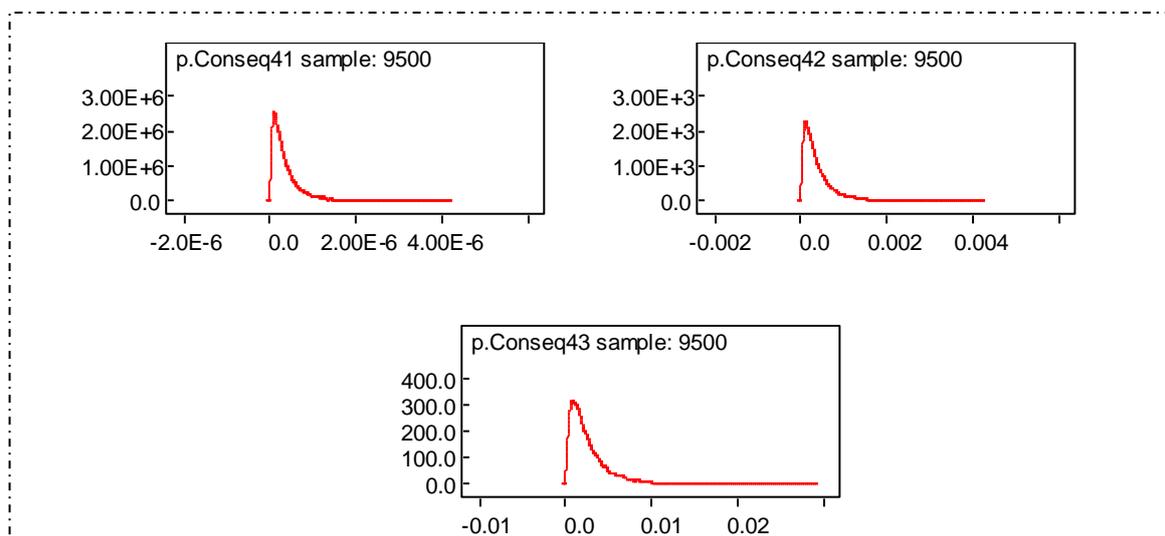


(b)

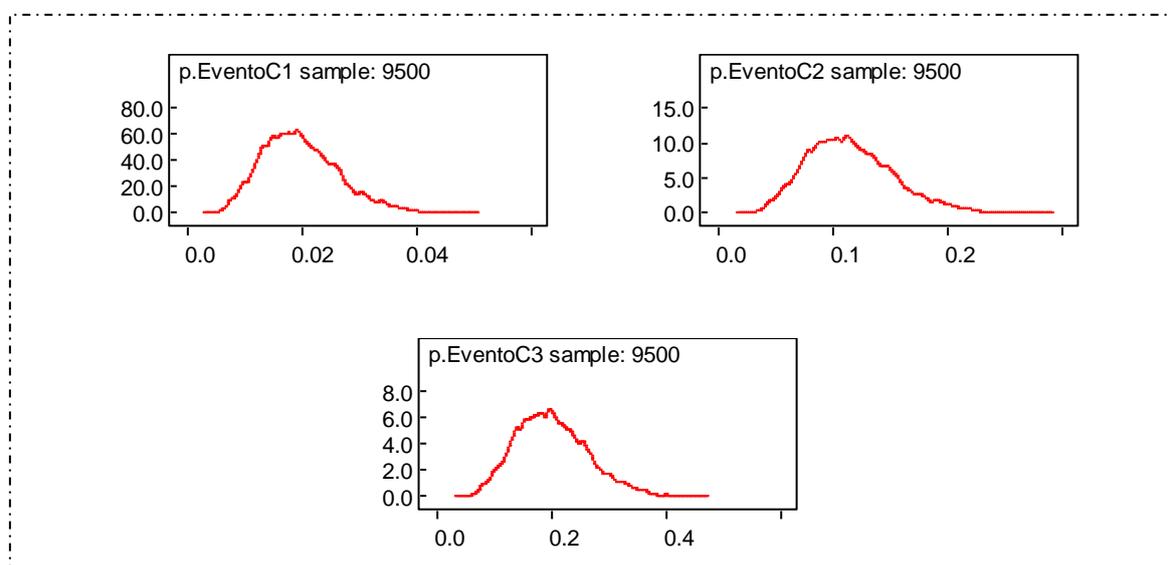




(c)



(d)



(e)

**Fonte:** A autora (2023)

Após as quatro hipóteses executadas é possível comparar os resultados do evento C, das barreiras e das probabilidades de ocorrência das consequências alcançadas em cada hipótese, como sumarizado na Tabela 21, para facilitar a visualização. Foram feitas três comparações (i) a hipótese 1 com a hipótese 3, em que mediante a rede bayesiana

estática, a primeira não tem incerteza e a terceira possui e (ii) as hipóteses 2 e 4, em que com a estrutura dinâmica foi comparado os valores com e sem tratamento da incerteza de dados, e (iii) 3 e 4, ao adicionar a condição dinâmica para os cenários com incerteza. Para a primeira e segunda comparações, como as hipóteses envolvem informações com e sem incerteza, o valor da média encontrada na hipótese 3 foi utilizada para comparar com os valores da hipótese 1, por ser uma estimativa pontual. Enquanto em (iii), os valores de 95% de confiança foram utilizados para comparação.

**Tabela 21:** Sumário dos resultados para as quatro hipóteses

<b>Hipótese 1</b>				
<b>T = 1200 h</b>	<b>P(Sucesso)</b>		<b>P(Falha)</b>	
Evento C	6.570E-1		3.429E-1	
<b>Probabilidade de Ocorrência</b>				
Consequência C <sub>1</sub>	3.209E-1			
Consequência C <sub>2</sub>	1.985E-2			
Consequência C <sub>3</sub>	2.054E-3			
Consequência C <sub>4</sub>	1.27E-4			
<b>Hipótese 2</b>				
<b>T = 1200 h</b>	<b>P(Sucesso)</b>		<b>P(Falha)</b>	
Evento C	8.4187E-01		1.5813E-01	
<b>Probabilidade de Ocorrência</b>				
Consequência C <sub>1</sub>	1.5408E-01			
Consequência C <sub>2</sub>	3.8647E-03			
Consequência C <sub>3</sub>	1.7495E-04			
Consequência C <sub>4</sub>	4.3881E-06			
<b>Hipótese 3</b>				
<b>Tempo T = 1200</b>	<b>Média</b>	<b>Sd</b>	<b>2.5%</b>	<b>95%</b>
Evento C	2.007E-1	6.177E-2	1.093E-1	3.099E-1
Consequência C <sub>1</sub>	1.548E-1	4.995E-2	8.180E-2	2.434E-1
Consequência C <sub>2</sub>	1.494E-2	1.084E-2	2.974E-3	3.629E-2
Consequência C <sub>3</sub>	2.821E-1	1.620E-2	8.406E-3	5.961E-2
Consequência C <sub>4</sub>	2.722E-3	2.478E-3	3.705E-4	7.555E-3
<b>Hipótese 4</b>				
<b>Tempo T = 1200</b>	<b>Média</b>	<b>Sd</b>	<b>2.5%</b>	<b>95%</b>
Evento C	2.003E-1	6.223E-2	1.064E-1	3.128E-1
Consequência C <sub>1</sub>	1.549E-1	5.031E-2	8.059E-2	2.468E-1
Consequência C <sub>2</sub>	1.478E-2	1.106E-2	2.763E-3	3.576E-2
Consequência C <sub>3</sub>	2.802E-2	1.648E-2	7.939E-3	5.952E-2
Consequência C <sub>4</sub>	2.657E-3	2.475E-3	3.603E-4	7.511E-3

Fonte: A autora (2023)

Na primeira comparação, os valores da hipótese 1 analisadas com os valores das médias da hipótese 3, as probabilidades de ocorrência das consequências 2, 3 e 4 da

hipótese 3 são menores, pois quando há a adição das evidências (dados de alto nível) no processo e da incerteza com a opinião de especialistas, os valores se tornam mais associados a realidade de ocorrência dos eventos. A consequência 1 possui probabilidade maior, pois está associado à ocorrência de um ambiente seguro, com o evento C estar no estado de sucesso, e de acordo com as evidências, o evento C tem pequena probabilidade de falhar.

Para a segunda comparação, com o tratamento de incerteza ao longo do tempo, ocorre a propagação da mesma junto com as informações das evidências. Comparando os valores da média gerado na hipótese 4 com os valores da hipótese 2 é observado que os valores mediante as incertezas são maiores, produzindo resultados mais fiel a realidade sobre as probabilidades de ocorrência dos eventos.

E para a terceira comparação, com a diferença entre as hipóteses sem e com a estrutura dinâmica para a propagação da incerteza, utilizando os valores com 95% de confiança para comparação, é observado que os valores sofrem pequenas modificações, visto que a incerteza ao longo do tempo gera essa diferenciação. As probabilidades de ocorrência para a hipótese 4 são menores quando comparadas a hipótese 3, visto que com a inspeção/teste no intervalo anterior é possível saber o estado do evento C e, portanto, reduz essa probabilidade de falha. A consequência 1 possui uma probabilidade maior na hipótese 4 do que na hipótese 3, pois para gerar essa consequência é quando há o sucesso do evento C, que devido a inspeção possui maior probabilidade de sucesso, pois é verificado esse estado, quando comparada com o caso de não ter inspeção/teste.

Essa metodologia apresentou como a dinâmica e a propagação da incerteza interferem nos valores das probabilidades de falha dos eventos e como a sua consideração proporciona valores mais realistas e conservadores. Para o caso de aplicação, o processo de cálculo será igual a da hipótese 4, com a adição da dinâmica e da propagação da incerteza pelo modelo bayesiano hierárquico.

## 4 A PROPOSTA DE APLICAÇÃO DA PESQUISA

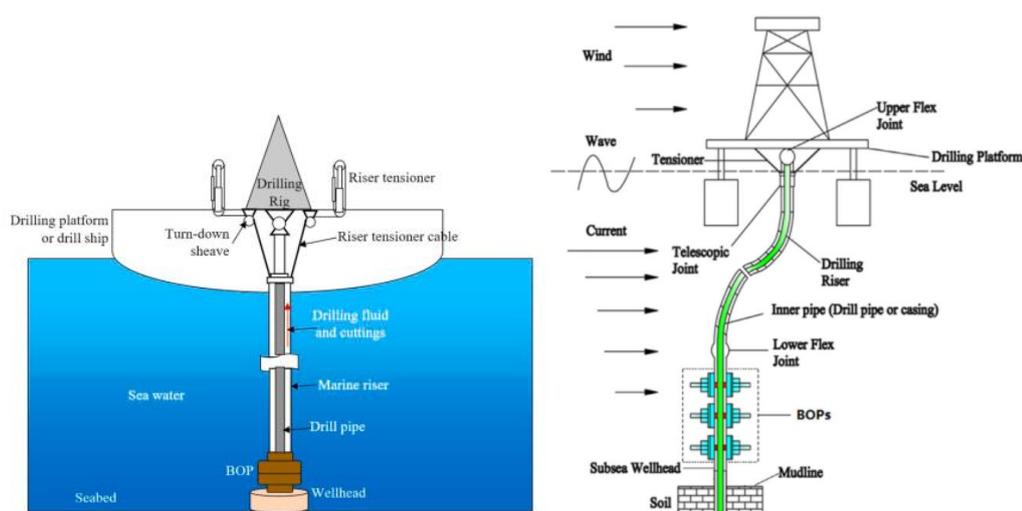
### 4.1 RISER DE PERFURAÇÃO E QUEBRA DE RISER

O processo de perfuração de um poço é feito por uma sonda com a ação de uma broca rotativa em que as rochas são perfuradas formando uma coluna de perfuração. Os fragmentos de rocha são retirados por bombeamento na coluna por meio da injeção de lama ou fluido de perfuração. Esse fluido tem a formação de uma mistura sólida, líquida, gases e produtos químicos. A partir da pressão hidrostática sobre as formações, ele resfria e lubrifica a coluna de perfuração e transporta os cascalhos do fundo do poço até a superfície. Uma grande quantidade de energia é requerida para cortar as formações rochosas que é transmitida por meio das rotações e o peso aplicado sobre as rochas para garantir a ruptura e a separação em pequenos tamanhos. Quando a broca alcança uma determinada profundidade, a coluna é retirada e é acoplada uma coluna de revestimento em aço de diâmetro inferior a broca e é realizada a cimentação entre os anulares dos tubos de revestimento, fornecendo assim maior segurança. Esse revestimento pode ser feito parcialmente ou totalmente com a finalidade de proteger as paredes devido ao risco de contaminação da água dos lençóis freáticos próximos, de desmoronamento, impedir a migração de outros fluidos de formação, sustentar outra coluna de revestimento, sustentar a cabeça do poço, entre outros riscos. Após esse procedimento, a perfuração é reiniciada com uma broca de diâmetro inferior a anterior e a mesma atividade é feita até atingir o último nível até o reservatório. Nessa perfuração em fases, os revestimentos são feitos com tubos de aço especiais, colocando uns por dentro dos outros, formando assim as colunas de revestimento (ROCHA e AZEVEDO, 2009). Portanto, a perfuração do poço é um processo de alto investimento e grandes desafios devido as diferentes formações rochosas e grandes profundidades. Durante esse processo é imprescindível que se mantenha a confiabilidade e a integridade do poço para que não ocorram acidentes causados por influxo indesejado. Um dos fatores que contribuem para isso é o conhecimento sobre o funcionamento e controle do *riser* de perfuração tanto em águas rasas quanto profundas.

O sistema de *riser* é um conjunto de tubos que conecta a sonda de perfuração ao BOP, a sua principal função é permitir a passagem de fluido de perfuração e sedimentos rochosos durante o processo de perfuração para a superfície. Esse transporte é realizado quando a lama ou um fluido sintético é bombeado para dentro da coluna de perfuração e esse fluido misturado com os sedimentos retorna pelos anulares até a sonda. As funções

secundárias do *riser* são o isolamento da água do mar e servir como suporte para as linhas de *kill* e de *choke* (LIU *et al.*, 2013). O sistema de *riser* possui características e especificações em sua estrutura, operação e manutenção que estão detalhadas na norma internacional ISO 13624-2 (2010). De acordo com a norma, o *riser* deve estar ligeiramente tensionado com valor de 20-25% do seu peso flutuante. Todavia, ao longo do *riser* as tensões verticais sofrem modificações significativamente devido a tensão de flexão e as pressões externas e internas. Uma característica específica é a necessidade de tensão no *riser* perto da superfície, entretanto ele deve estar em compressão quando localizado mais perto do *Blowout Preventer* (BOP) (BERNISTAS, 1982).

O sistema de *riser* é composto por conduítes (corpo do *riser*), conexões entre as juntas do *riser*, componentes auxiliares como endurecedores de ancoragem, fluviabilidade, e interface entre o flutuador e o BOP (BAI e BAI, 2010), como mostra a Figura 21. De forma mais detalhada, os principais componentes do *riser* de perfuração são especificadamente o sistema de tracionadores, o LMRP/BOP, a junta telescópica (*telescopic joint* – TJ), junta flexível inferior (*lower flex joint* - LFJ), junta flexível superior (*upper flex joint* - UFJ) e juntas lisas e flutuantes. O sistema de tracionadores conecta a extremidade superior da coluna do *riser* com a sonda e tem a função de aplicar tração vertical no topo do *riser* controlando os deslocamentos e as tensões. O LMRP/BOP é o equipamento que fica abaixo do *riser* que tem a finalidade de realizar a desconexão entre eles quando necessário, por meio dos PODs. A junta telescópica tem a finalidade de ajudar na compensação visto o comprimento do *riser* e a movimentação da plataforma. As juntas flexíveis permitem o desalinhamento entre o *riser* e o BOP, que colabora para evitar o movimento de flexão excessivo que provoca altos danos ao tubo, proporcionando assim um melhor desempenho mecânico nas extremidades da coluna (CHANG, 2018; API 16Q, 1993). As juntas lisas e flutuantes do *riser* são os principais componentes da coluna do *riser*, cujo além do tubo principal há também tubos auxiliares com as funções de linha de *kill/choke*, linha de controle e potência hidráulica para o BOP. O *riser* é dividido em várias seções que unidas permitem construir o seu comprimento (CHANG, 2018). A Figura 21 apresenta uma exemplificação da estrutura de um *riser* de perfuração com seus componentes.

**Figura 21:** Estrutura do *riser* de perfuração

**Fonte:** Nguyend e Al-safran (2021) e Chang *et al.* (2019)

O *riser* está sujeito às condições de cargas impactantes para a segurança do processo de perfuração. As cargas que agem sobre a coluna de perfuração são identificadas como cargas ambientais e cargas funcionais. As cargas funcionais são relacionadas as forças térmicas, forças residuais, pressão externa e interna, e o peso do duto. Os possíveis danos causados por essas cargas são a corrosão dos parafusos e a redução da espessura da parede do tubo devido ao desgaste e fadiga produzindo rachaduras. Essa corrosão pode ocorrer também na parte externa do tubo causada pela falta de revestimento anticorrosivo. Além da corrosão, pode haver o desgaste do *riser* quando há o contato em potencial do tubo de perfuração rotativo com a superfície interna do tubo principal. Os impactos como rachaduras, danos à superfície, desgaste excessivo e corrosão são encontrados nas juntas. Por outro lado, as cargas ambientais estão associadas as condições do meio ambiente como grandes ondas, fortes ventos e alta correnteza.

A soma dessas cargas com a ocorrência de perda de posição do sistema de posicionamento dinâmico (DP) permite o deslocamento crescente da sonda o que gera uma grande força horizontal e um momento de flexão ao sistema de *riser*. Quando isso ocorre é acionado o sistema de desconexão de emergência que evita possíveis acidentes de fratura do mesmo ao desconectar o *riser* abaixo do LMRP (LANG *et al.*, 2009, CHANG *et al.*, 2018, LIU *et al.*, 2013), e em caso de não sucesso da desconexão de emergência, as tensões no *riser* podem levar a sua fratura. A falha do sistema de

desconexão está associada a falha dos equipamentos de detecção e erros humanos que resultam em imprecisão nos valores. Essa atuação humana ocorre de acordo com os planos de emergência pré-estabelecidos após o controle do poço (TAYLOR *et al.*, 2018).

A quebra de *riser* pode ocorrer em atividades de construção e intervenção em poços, tanto durante a descida ou subida do *riser* assim como durante a operação. As principais consequências para essa situação é a fratura do *riser*, colapso do tubo, vazamento das linhas de *kill/choke* e falha do equipamento auxiliar e aterramento da coluna suspensa do *riser* (HOLAND *et al.*, 2001; XU *et al.*, 2013; LIU *et al.*, 2013; CHANG *et al.*, 2018a). Foram registrados sete grandes acidentes de *riser* que englobam desconexão do conector devido corrosão, quebra do *riser*, explosão do tubo principal gerada por desgaste, vazamento nas linhas e *kill/choke*, entre outras causas (FIGUEIREDO *et al.*, 2023). Um exemplo de ocorrência de fratura do *riser* de perfuração ocorreu no Golfo do México em 2003 causado por uma tensão excessiva aplicada nos *risers* quando puxados pelo navio sonda *Discoverer Enterprise*, assim como o deslocamento da plataforma e o desgaste da tubulação com o tubo de perfuração rotativo durante as operações de perfuração (KIRTON *et al.*, 2004). A fratura pode ocorrer em qualquer local em que há um ponto fraco durante as operações de perfuração entre o sistema de BOP e o *riser*. A partir dos estudos de Simonsen (2014) e Figueredo *et al.* (2023) foi identificado o número de ocorrências de acidentes com *riser* associadas as causas raízes. Os modos de falha mais ocorridos em *risers* encontrados nos acidentes no Brasil foram o colapso do *riser*, seguido pela falha por fadiga, falha compressiva, corrosão, dano externo e falha por tração.

É importante realizar o controle com monitoramento e inspeções no *riser* a fim de tentar prevenir e mitigar os acidentes graves (DRUMOND *et al.*, 2018; SUBSEA, 2013). A política de manutenção do *riser* normalmente ocorre após uma campanha de perfuração, e o conjunto de *riser* é encaminhado para a terra para avaliação completa, ocorrendo mais ou menos a cada 5 anos (CHANG *et al.*, 2018b). A realização de inspeções colabora para manter as juntas do *riser* em boas condições reduzindo a probabilidade de problemas estruturais como fissuras e rachaduras. Para o cenário de degradações, os processos de manutenção do *riser* podem ou não detectarem a falha, o que gera um risco de ocorrer a fratura durante a perfuração. A manutenção do *riser* é controlada por um programa da unidade e atende as recomendações do fabricante em que está incluída uma rotina de inspeção das partes críticas. No que tange a fabricação, existem os processos de controle de qualidade rigorosos dos fabricantes do *riser*. De

acordo com os dados da ANP (2021), não foi observado nenhum histórico de quebra de *riser* atribuído a fabricação ou falha de manutenção.

Além das manutenções e inspeções, as barreiras de segurança também são elementos associadas ao sistema de *riser* com o objetivo de manter o ambiente seguro após a ocorrência do evento de quebra. Essas barreiras são elementos de contorno do sistema afim de que o fluído não se comunique com o meio externo. Cada barreira representa os caminhos possíveis entre o poço e o meio ambiente, podendo ser ele um anular ou coluna (MIURA, 2004). A falha das barreiras permite a ocorrência de vazamentos de múltiplas magnitudes, por isso, são adicionadas na análise de risco.

#### 4.2 BARREIRA DE SEGURANÇA DO EVENTO DE QUEBRA DE RISER

A barreira de segurança é definida como uma barreira física ou/e não física planejada para prevenir, controlar ou mitigar eventos indesejados ou acidentes. Isso pode variar desde uma única unidade técnica ou uma ação para um sistema sociotécnico complexo e estruturado (SKLET, 2006). Para o cenário de quebra de *riser*, existem algumas barreiras de segurança que são acionadas para que não haja grandes vazamentos com a ocorrência de *blowout*.

De acordo com Chang *et al.* (2018) e Chang *et al.* (2019), uma das barreiras de segurança para evitar acidentes com danos a pessoas e equipamentos devido a ocorrência de fratura do *riser* é o recuo do sistema tensionadores após a fratura. Esse sistema é importante dado que o *riser* está tensionado e uma específica quantidade de tração é necessária para mantê-lo sob tensão. Quando há a ocorrência da fratura, a grande quantidade de energia potencial armazenada na coluna do *riser* sob tensão é liberada rapidamente, resultando em um considerável deslocamento axial e aceleração em um espaço de tempo muito curto. Caso não haja o controle desse movimento gerado pela energia liberada pelo sistema de controle de tensionadores, ele pode levar a danificação dos equipamentos ao longo do caminho de recuo, assim como gerar danos para o sistema de perfuração.

A quebra de *riser* impede a comunicação elétrica e hidráulica com o BOP, o que, concomitantemente, interrompe a conexão com o sistema de controle do BOP. A comunicação do BOP com a sonda é realizada por meio de uma comunicação eletro-hidráulica conhecido como sistemas de controle principais. A finalidade desses sistemas em condições normais de operação é acionar as funções do BOP como a vedação,

desconexão do LMRP, fechamentos das gavetas de corte e controle das válvulas submarinas. Caso haja a falha desses sistemas principais para acionamento dessas funções, o sistema do BOP possui sistemas secundários de emergência. Os sistemas secundários são o *deadman/autoshaer*, o EDS (*Emergency Disconnection Sequence*), o sistema acústico e a interface para acionamento via ROV (*Remotely Operated Vehicles*) (API STD 53, 2018).

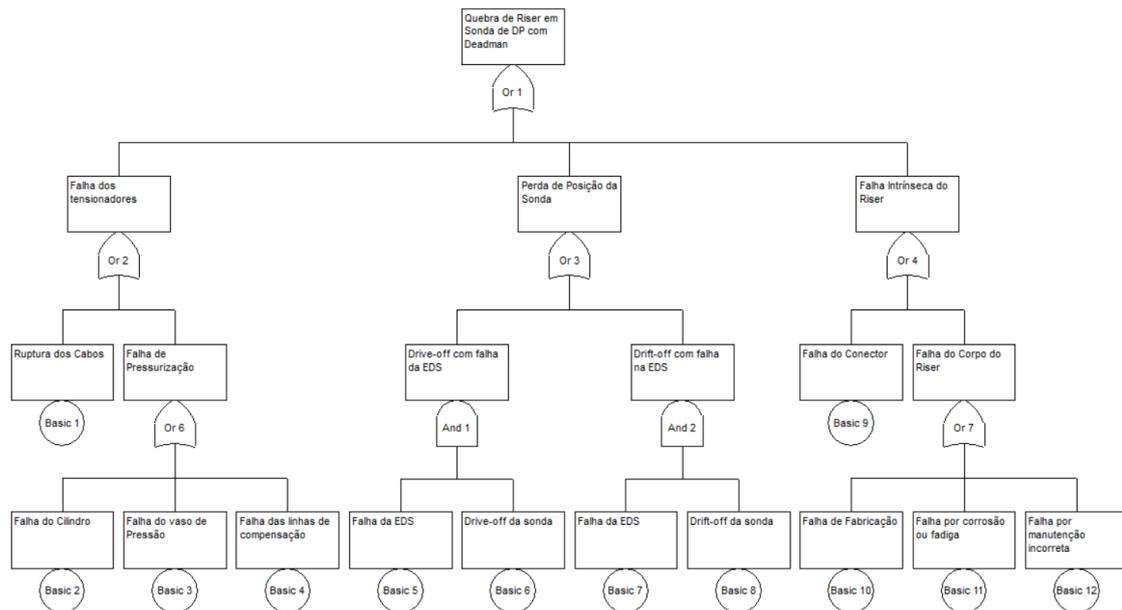
O sistema *autoshear* (AS) é um sistema que quando ativado aciona o fechamento da gaveta cisalhante usando o fluido de alta pressão armazenado nos acumuladores inferiores do BOP quando há um evento de liberação do LMRP não planejado. O *deadman* (DMS) é ativado quando há uma perda de energia elétrica ou de sinal levando a uma perda hidráulica, quando acionado também fecha a gaveta cisalhante usando os acumuladores inferiores do BOP. O *deadman* e o *autoshear* são acionados automaticamente, sem a necessidade de interferência humana. O sistema *autoshear* tem o objetivo de fechar o poço no caso de desconexão do LMRP (*Lower Marine Riser Package*), enquanto o *deadman* é projetado para fechar o poço no caso de ausência de suprimento hidráulico e sinal de controle de ambos PODs submarinos, simultaneamente. O sistema acústico tem a finalidade de fechar as gavetas cisalhantes e/ou cegas-cisalhantes por meio da atuação humana. Essa atuação depende da percepção da quebra de *riser*, da execução do acionamento e do correto funcionamento do sistema. Esse sistema acústico é instalado no BOP e possui seus próprios acumuladores que possuem como função executar a operação de cisalhamento em alta pressão. O uso do sistema acústico é opcional e é caracterizado como um sistema de emergência secundário. O ROV *Intervention* tem a função de fechar a gaveta cisalhante e prover fluido de alta pressão ao operador ao ser acionado via painel de controle hidráulico (SHANKS *et al.*, 2012).

A ocorrência da quebra de *riser* pode gerar consequências com diferentes volumes de vazamentos e localidades de dissipação do fluido. Elas podem ser divididas em três grupos, sendo o primeiro grupo o vazamento do fluido localizado no interior do *riser*, o segundo caracterizado pelo pequeno vazamento de um volume de fluido no poço ocorrido devido ao tempo de resposta para acionamento do sistema acústico e o terceiro um vazamento descontrolado de fluido que gera a ocorrência de um *blowout*. Portanto, essas barreiras são fundamentais para tentar controlar a ocorrência de vazamentos gerada pela liberação de um influxo indesejado pelo evento de fratura do *riser*.

## 5 ANÁLISE E DISCUSSÃO DOS RESULTADOS

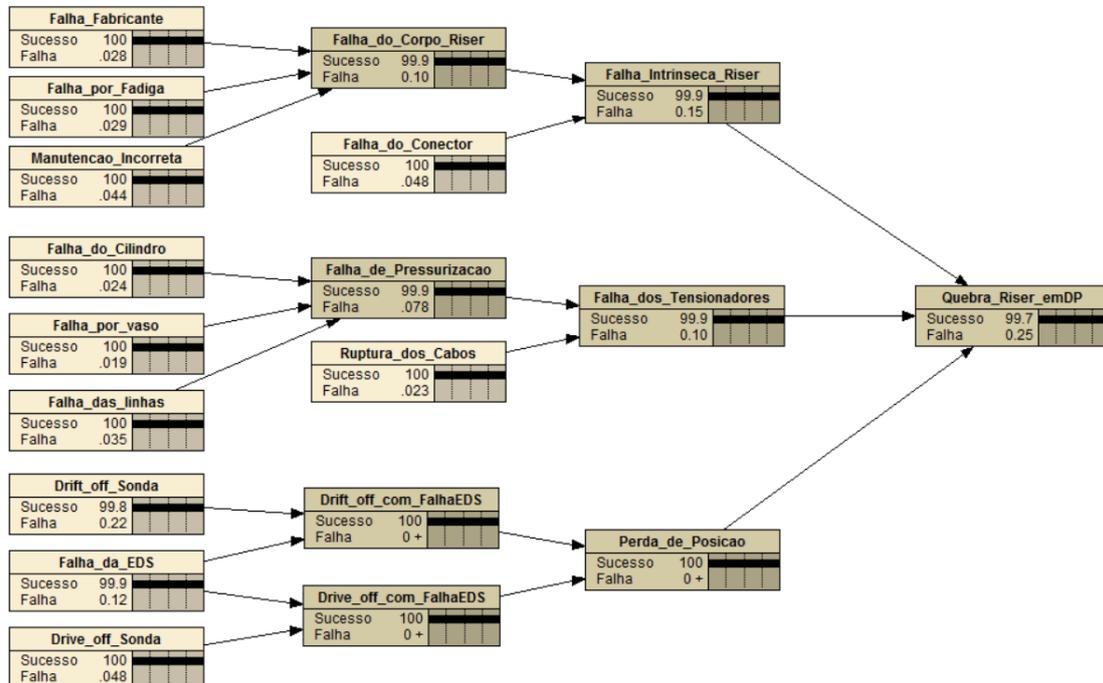
A aplicação da metodologia para o evento de quebra de *riser* considerou as causas do evento estarem associadas a fatores internos e externos ao *riser* de perfuração. Os fatores internos ou intrínsecos são referentes a falha dos conectores ou no corpo do *riser*, ocorridos devido à problemas na fabricação ou na degradação ocasionados na operação. As falhas externas englobam a falha no sistema de tensionamento do *riser* ou por um deslocamento da sonda de posicionamento dinâmico sem a desconexão do *riser*. O sistema de tensionadores inclui cilindros, vasos de pressão, linhas dos tensionadores e os cabos de tensão que têm por finalidade colaborar na transferência de força de tração para o *riser*. Para o caso de deslocamento da plataforma sem a desconexão do *riser*, isso pode acontecer por duas situações, *drift-off* ou *drive-off*. O *drift-off* ocorre quando há uma perda de posição causada por uma perda parcial ou total das capacidades propulsivas que leva a embarcação ficar à deriva. Isso pode ser causado por uma falha do sistema de energia, no sistema de controle de posicionamento dinâmico (DP), falha do sistema de propulsores ou falta de combustível. O *drive-off* ocorre quando essa perda de posição é causada por uma força indesejada aplicada ao sistema de posicionamento dinâmico (DP) ou algum problema de instabilidade no sistema de controle de DP levando a sonda em uma direção indevida (SILVA, 2015). Além desses dois fatores, a ocorrência de perda de posição da sonda também pode ocorrer por uma falha no sistema de desconexão de emergência (EDS). Portanto, as causas de ocorrência de quebra de *riser* são baseadas em três eventos, a falha dos tensionadores, falha intrínseca do *riser* e a perda de posição da unidade sem desconectar o *riser*. A Figura 22 representa a árvore de falha para a o evento de quebra de *riser* e os seus eventos causais, reproduzido no software CARA. A partir dessa árvore de falha é construída a rede bayesiana dinâmica para os tempos  $T_0 = 0$ ,  $T_1 = 672$ ,  $T_2 = 1344$ ,  $T_3 = 2016$  horas. Esse tempo foi escolhido visto que o BOP é testado a cada 28 dias e o tempo considerado do BOP instalado na sonda é de 85 dias. A Figura 23, construída no software Netica, apresenta o caso do evento de quebra de *riser* com as taxas de falha constantes (Hipótese 1) no tempo  $T_3 = 2016$  horas para fins de comparação, sendo esse as condições da primeira hipótese apresentada na metodologia.

**Figura 22:** Árvore de falha para o evento de quebra de *Riser*



Fonte: A autora (2023)

**Figura 23:** Rede Bayesiana dinâmica para o evento de quebra de *riser* para 2016 horas



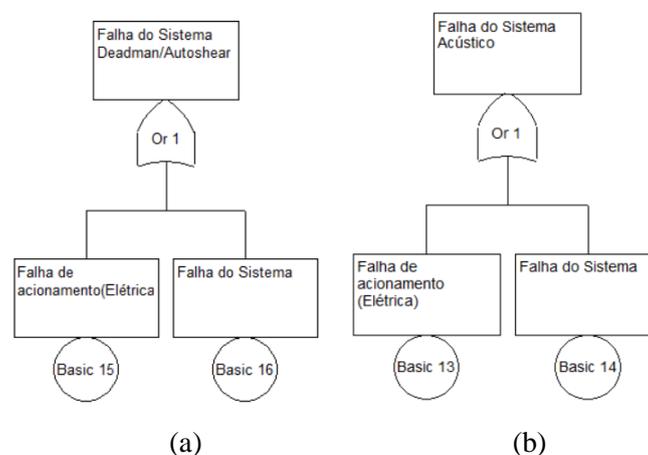
Fonte: A autora (2023)

As barreiras de mitigação são utilizadas quando há a ocorrência do evento de quebra de *riser* a fim de manter a integridade do poço durante o processo de perfuração,

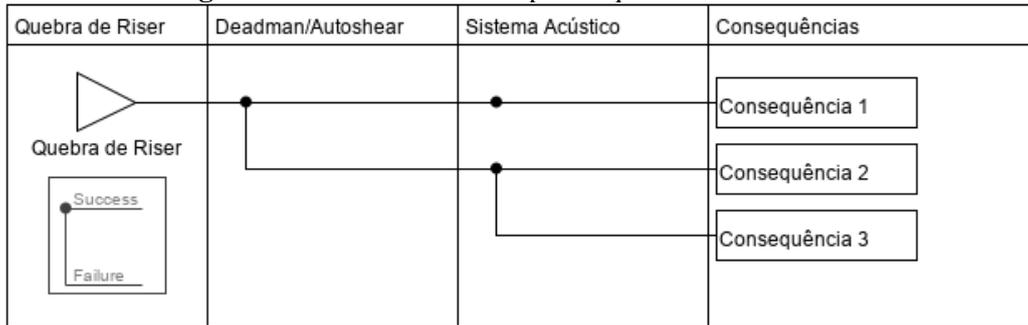
e por isso, são utilizadas na análise. As barreiras de segurança consideradas para esse estudo são o sistema *deadman/Autoshear* e o acústico. O sistema de ROV poderia ser utilizado como barreira para esse caso, entretanto por esse recurso demandar um tempo longo de mobilização, ele não foi considerado como barreira para essa análise.

Essas barreiras são fundamentais para manter o controle do poço e não permitir que consequências severas possam acontecer após a quebra do *riser*. As possíveis consequências associadas a esse evento podem ser topicalizadas em três pontos, a primeira é o vazamento do fluido localizado no interior do *riser*, seguida pelo pequeno vazamento de um volume de fluido no poço para o meio ambiente, e o terceiro sendo um vazamento descontrolado de fluido que gera a ocorrência de um *blowout*. Após a quebra de *riser*, a consequência gerada é um pequeno vazamento no interior do *riser* quando há o funcionamento do *deadman/autoshear*. Entretanto, caso esse sistema falhe, há um pequeno vazamento do fluido para fora do poço, pois ainda há a barreira acústica que permite o controle do fluido. Todavia, caso esse sistema falhe, há um vazamento descontrolado, ocorrendo assim um *blowout* (CHANG et al, 2019). As árvores de falha das barreiras de segurança são as barreiras de *deadman/Autoshear* e o sistema acústico, que possuem dois eventos básicos, sendo um relacionado a uma falha elétrica e a falha do sistema em si. Elas estão detalhadas na Figura 24. A Figura 25 apresenta a árvore de evento que contém a associação entre a falha das barreiras e as consequências geradas. Para esse estudo, o reservatório a ser considerado foi o exposto, o que permite a utilização do *deadman* como barreira, visto a incerteza associada ao reservatório.

**Figura 24:** Árvore de falha das barreiras de segurança (a) Deadman/Autoshear (b) Acústico



**Fonte:** A autora (2023)

**Figura 25:** Árvore de Evento para a quebra/fratura de *Riser*

**Fonte:** A autora (2023)

Onde:

$C_1$  – Vazamento do fluido localizado no interior do *riser*

$C_2$  – Pequeno vazamento de um volume de fluido no poço para o meio ambiente

$C_3$  – Vazamento descontrolado de fluido (*Blowout*)

Os valores das probabilidades de ocorrência das consequências para os três intervalos de tempo ocorrem pela multiplicação das probabilidades do sucesso e da falha de cada barreira em cada intervalo. A Tabela 22 indica como é o processo de cálculo da probabilidade das respectivas consequências em cada caminho da árvore de evento.

**Tabela 22:** Cálculo multiplicativo para cada caminho da árvore de evento

Consequências	Probabilidades
$C_1$ – Consequência 1	$P_r \times (1 - P_1)$
$C_2$ – Consequência 2	$P_r \times (P_1) \times (1 - P_2)$
$C_3$ – Consequência 3	$P_r \times (P_1) \times (P_2)$

**Fonte:** A autora (2023)

Onde:

$P_r$  – Probabilidade de quebra do *riser*

$P_1$  – Probabilidade de falhar o sistema *Deadman/Autoshear*.

$P_2$  – Probabilidade de falha do sistema Acústico.

As taxas de falha dos eventos básicos da quebra de *riser* e das barreiras de segurança são definidos por uma distribuição lognormal com os parâmetros de variância ( $\tau$ ) e média ( $\mu$ ) contido na Tabela 23, em que são baseadas em banco de dados genéricos.

**Tabela 23:** Parâmetros de cada evento básico da quebra de *riser* e das barreiras de segurança

Eventos Básicos	Nº dos Eventos	Média ( $\mu$ ) (h)	Variância (c)	Fonte
Falha do Conector	Básico 9	2.40E-07	4	RAPID-S53
Falha por corrosão ou fadiga	Básico 11	1.46E-07	4	OREDA
Falha por Manutenção Incorreta	Básico 12	2.20E-07	4	OREDA
Falha de Fabricação	Básico 10	1.35E-07	4	RAPID-S53
Ruptura dos Cabos	Básico 1	1.13E-07	4	RAPID-S53
Falha do Cilindro	Básico 2	1.18E-07	4	OREDA
Falha do Vaso de Pressão	Básico 3	9.60E-08	4	OREDA
Falha das Linhas de compressão	Básico 4	1.75E-07	4	OREDA
<i>Drive-off</i> da sonda	Básico 6	2.40E-07	4	RAPID-S53
Falha da EDS	Básico 7	5.84E-07	4	RAPID-S53
<i>Drift-off</i> da sonda	Básico 8	1.07E-06	3	RAPID-S53
Falha no Sistema Acústico	Básico 14	8.00E-05	0.5	Subsea BOP reliability, testing, and well kicks (Exprosoft, 2019)
Falha do Deadman	Básico 16	6.18E-05	0.6	RAPID-S53
Falha elétrica das barreiras	Básico 13	3.00E-06	2	IEEE (2015)

**Fonte:** A autora (2023)

De acordo com a pesquisa de Figueredo (2023) houve 43 acidentes relacionados ao *riser* de perfuração e produção com múltiplos modos de falha, em que 1 deles ocorreu por fratura do *riser* de perfuração no período de 2013 a 2022 baseados em históricos do relatório anual da ANP de 2022. Portanto, o número de ocorrências consideradas para o evento de quebra de *riser* será de 1 falha. Para a definição das consequências com a quebra de *riser*, é utilizado a mesma demanda como dado de alto nível que o considerado para a quebra de *riser*, entretanto, a consequência ocorrida foi de um pequeno vazamento em que o sistema de *deadman/autoshear* e o acústico foram acionados, portanto, a consequência 2 aconteceu e as outras não ocorreram. Ambas seguindo uma distribuição binomial com os respectivos valores de demanda e número de ocorrências.

Para as barreiras de segurança, as evidências encontradas sobre o evento de falha são definidas por uma distribuição binomial, e os valores dos parâmetros utilizados são baseados em dados do RAPID S53 sumarizados na Tabela 24.

**Tabela 24:** Informações de evidências sobre as barreiras de segurança

Barreiras de Segurança	Demanda (n)	Ocorrências (x)
<i>Deadman/Autoshear</i>	45 demandas	1 falha
Acústico	67 demandas	1 falha

Fonte: RAPID S53

Para gerar as taxas de falha dos eventos básicos foi usado a simulação de Monte Carlo com 10.000 interações no Winbugs.

Para realizar as comparações, as hipóteses apresentadas na proposta metodológica foram calculadas para essa aplicação. Para a primeira hipótese, em que as taxas de falha são constantes, a probabilidade do evento indesejado encontra-se na Figura 23, e para as consequências e as barreiras, a Tabela 25 apresenta os resultados para o período de  $T_3 = 2016$  horas. Para a segunda hipótese, em que há uma dinâmica no processo sem considerar a incerteza, os resultados também se encontram na Tabela 25.

**Tabela 25:** Resultados das distribuições *a posteriori* das consequências e do evento iniciador para a primeira e segunda hipótese de aplicação.

<b>Hipótese 1</b>		
<b><math>T_5 = 2016</math> h</b>	<b>P(Sucesso)</b>	<b>P(Falha)</b>
Quebra de <i>Riser</i>	9.975E-1	2.505E-3
<b>Probabilidade de Ocorrência</b>		
Consequência $C_1$	2.4897E-03	
Consequência $C_2$	1.5440E-05	
Consequência $C_3$	9.7144E-08	
<b>Hipótese 2</b>		
<b><math>T_1 = 672</math> h</b>	<b>P(Sucesso)</b>	<b>P(Falha)</b>
Quebra de <i>Riser</i>	9.99916E-01	8.351E-05
<b>Probabilidade de Ocorrência</b>		
Consequência $C_1$	8.3489E-05	
Consequência $C_2$	1.7296E-08	
Consequência $C_3$	3.6132E-12	
<b><math>T_2 = 1344</math> h</b>	<b>P(Sucesso)</b>	<b>P(Falha)</b>
Quebra de <i>Riser</i>	9.99908E-01	9.18558E-05
<b>Probabilidade de Ocorrência</b>		
Consequência $C_1$	9.1835E-05	
Consequência $C_2$	2.0924E-08	
Consequência $C_3$	4.8074E-12	
<b><math>T_3 = 2016</math> h</b>	<b>P(Sucesso)</b>	<b>P(Falha)</b>
Quebra de <i>Riser</i>	9.99073E-01	9.26956E-04
<b>Probabilidade de Ocorrência</b>		
Consequência $C_1$	9.2483E-04	
Consequência $C_2$	2.1260E-06	
Consequência $C_3$	4.9390E-09	

Na Tabela 25 é apresentado a probabilidade de sucesso e falha da quebra de *riser*, o que indica que para a hipótese 1, por exemplo, a probabilidade de ocorrência da quebra de *riser* é  $2.505E-3$ , enquanto ao contrário, a probabilidade de não ocorrência é  $9.975E-1$ , para o período de tempo  $T_3 = 2016$  h. Para o caso 2, a tabela contém os valores para os outros intervalos de tempo  $T_1 = 672$ ,  $T_2 = 1344$  e  $T_3 = 2016$  h.

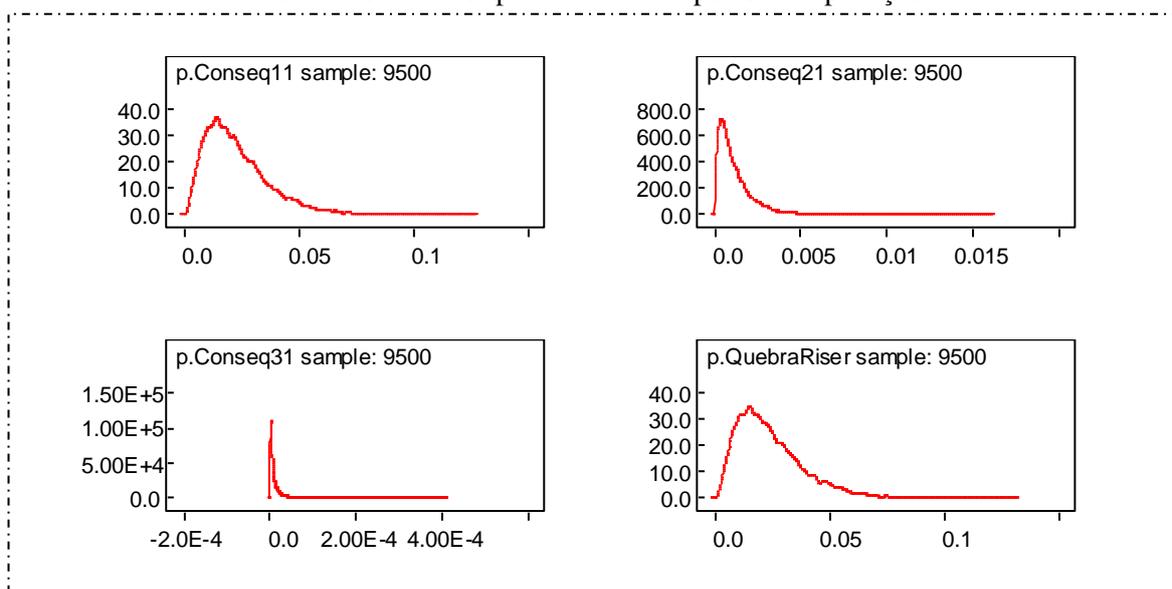
Para as condições da terceira hipótese, em que há a adição da opinião de especialistas e dados de alto nível, em que há a inclusão da incerteza, entretanto não há a dinâmica do processo, os valores obtidos estão apresentados na Tabela 26 para o período de  $T_3 = 2016$  h. O apêndice 4 contém o código utilizado nesse caso de aplicação. O Gráfico 3 apresenta os gráficos das distribuições *a posteriori* para as consequências, as barreiras de segurança e o evento iniciador.

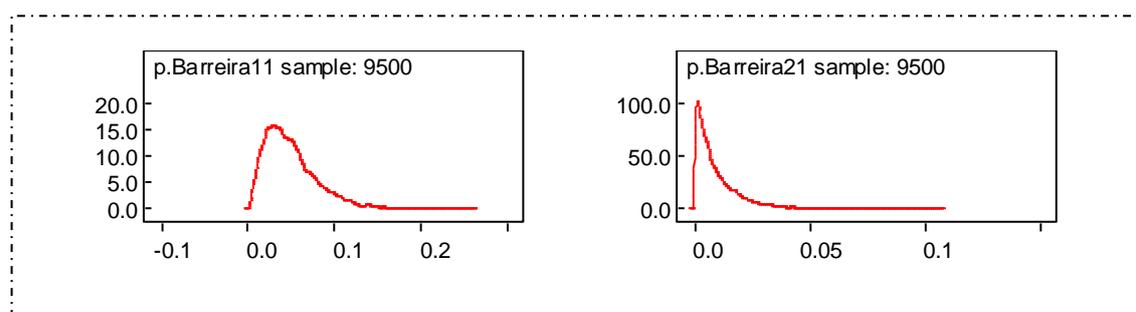
**Tabela 26:** Resultados das distribuições *a posteriori* das consequências e do evento iniciador para a terceira hipótese de aplicação.

<b>Hipótese 3</b>				
<b>Tempo <math>T_3 = 2016</math></b>	<b>Média</b>	<b>Sd</b>	<b>5%</b>	<b>95%</b>
Quebra de <i>Riser</i>	2.404E-2	1.482E-2	6.226E-3	5.269E-2
Barreira Deadman	4.901E-2	3.058E-2	1.147E-2	1.077E-1
Barreira Acústico	9.565E-3	1.027E-2	5.245E-4	3.006E-2
Consequência $C_1$	2.286E-2	1.413E-2	5.889E-3	4.988E-2
Consequência $C_2$	1.168E-3	1.117E-2	1.455E-4	3.255E-3
Consequência $C_3$	1.15E-5	2.063E-5	2.636E-7	4.475E-5

Fonte: A autora (2023)

**Gráfico 3:** Gráficos das distribuições *a posteriori* das consequências, das barreiras de segurança e do evento iniciador para a terceira hipótese de aplicação.





Fonte: A autora (2023)

O resultado encontrado para a probabilidade de ocorrência da quebra de *riser* na hipótese 3 (pela média) ao comparar com a hipótese 1, é maior, demonstrando que como os dados de alto nível atualizam a probabilidade de ocorrência da quebra do *riser* e das consequências, e como houve um acidente relacionado a esse evento, essas probabilidades de ocorrência de vazamentos pela quebra de *riser* é maior que quando apenas considerando as taxas de falha constante sem nenhuma evidência.

Para o quarto caso, em que há a dinâmica e a propagação da incerteza para o *bowtie*, os valores encontrados *a posteriori* para as consequências e do evento iniciador nos três intervalos de tempo são apresentadas no Gráfico 4 e na Tabela 27. Para esse caso, a inspeção incompleta ocorre nos eventos básicos do evento indesejado e das barreiras de segurança. O apêndice 5 contém o código utilizado nesse caso de aplicação.

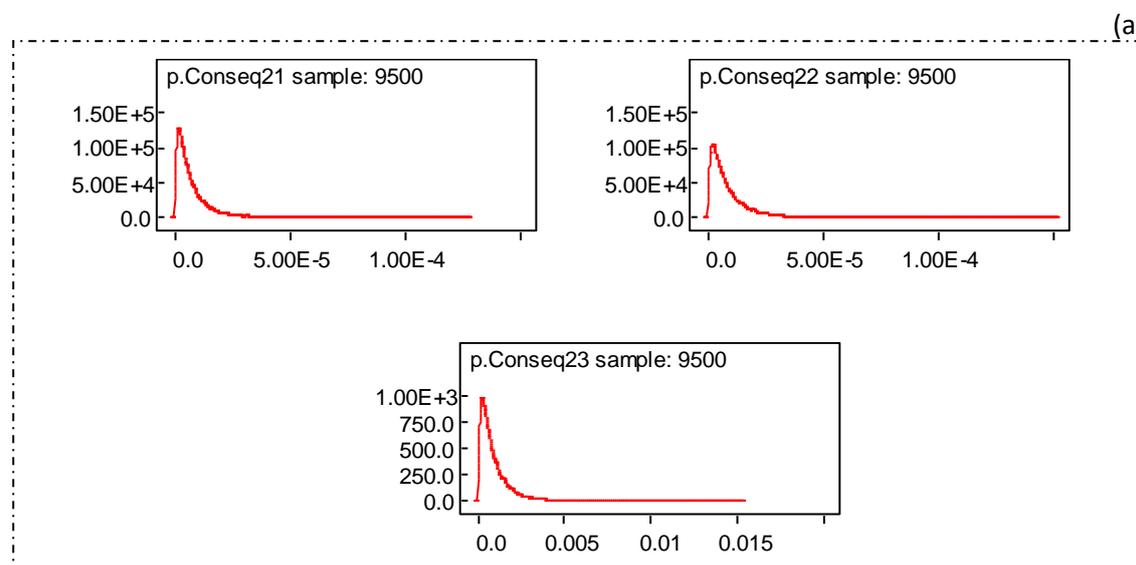
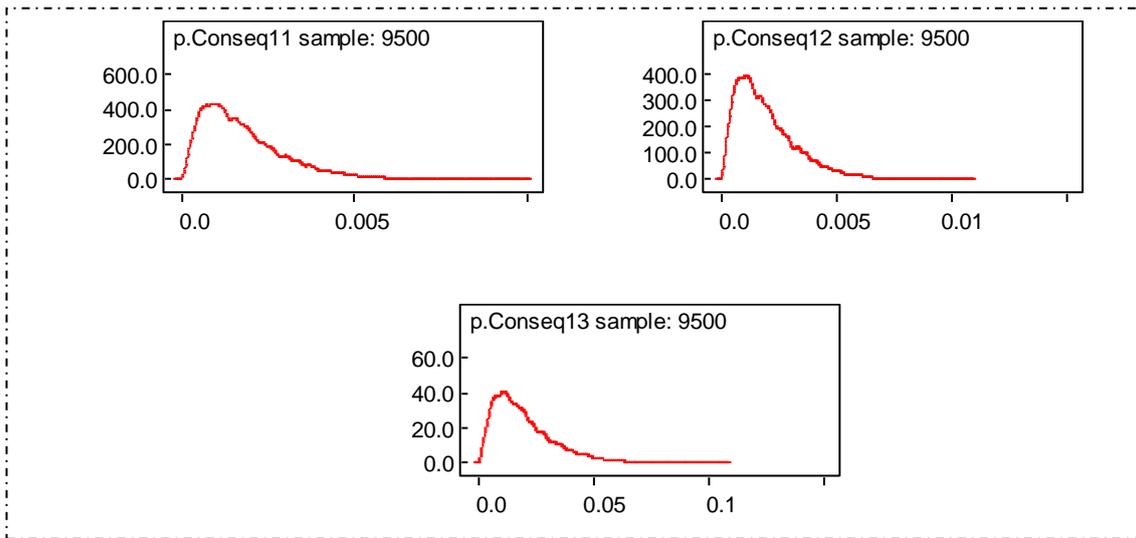
**Tabela 27:** Resultados das distribuições *a posteriori* das consequências, das barreiras de segurança e do evento iniciador

<b>Hipótese 4</b>				
<b>Tempo T = 672 h</b>	<b>Média</b>	<b>Sd</b>	<b>5%</b>	<b>95%</b>
Quebra de <i>Riser</i>	1.801E-3	1.25E-3	2.625E-4	4.256E-3
Consequência C <sub>1</sub>	1.793E-3	1.245E-3	3.637E-4	4.237E-3
Consequência C <sub>2</sub>	7.428E-6	8.035E-6	7.709E-7	2.264E-5
Consequência C <sub>3</sub>	5.275E-9	1.090E-8	8.455E-11	2.073E-8
Barreira Deadman	4.114E-3	2.678E-3	9.15E-4	9.263E-3
Barreira Acústico	7.086E-4	8.399E-4	3.232E-5	2.384E-3
<b>Tempo T = 1344 h</b>	<b>Média</b>	<b>Sd</b>	<b>5%</b>	<b>95%</b>
Quebra de <i>Riser</i>	1.978E-3	1.37E-3	4.041E-4	4.666E-3
Consequência C <sub>1</sub>	1.969E-3	1.364E-3	4.025E-4	4.643E-3
Consequência C <sub>2</sub>	8.933E-6	9.619E-6	9.345E-7	2.705E-5
Consequência C <sub>3</sub>	6.969E-9	1.434E-8	1.13E-10	2.743E-8
Barreira Deadman	4.522E-2	2.916E-2	1.006E-3	1.012E-2
Barreira Acústico	7.784E-4	9.214E-4	3.555E-5	2.618E-3
<b>Tempo T = 2016 h</b>	<b>Média</b>	<b>Sd</b>	<b>5%</b>	<b>95%</b>
Quebra de <i>Riser</i>	2.058E-2	1.391E-2	4.528E-3	4.804E-2
Consequência C <sub>1</sub>	1.965E-2	1.328E-2	4.331E-3	4.606E-2
Consequência C <sub>2</sub>	9.27E-4	9.781E-4	1.014E-4	2.79E-3

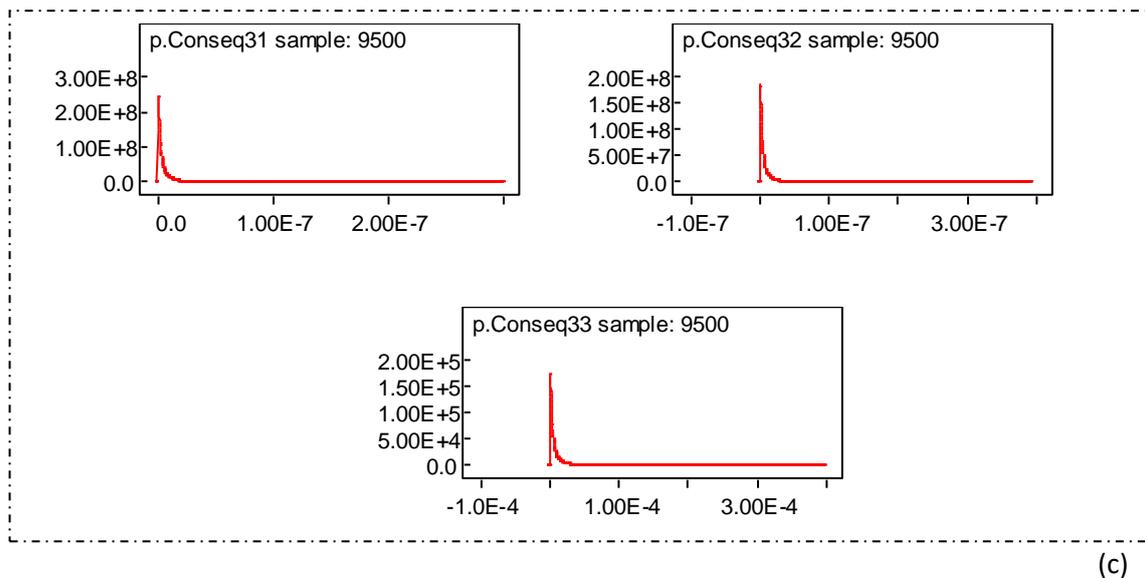
Hipótese 4				
Consequência C <sub>3</sub>	7.288E-6	1.466E-5	1.218E-7	2.829E-5
Barreira Deadman	4.522E-2	2.916E-2	1.014E-2	1.013E-1
Barreira Acústico	7.841E-3	9.262E-3	3.587E-4	2.635E-2

Fonte: A autora (2023)

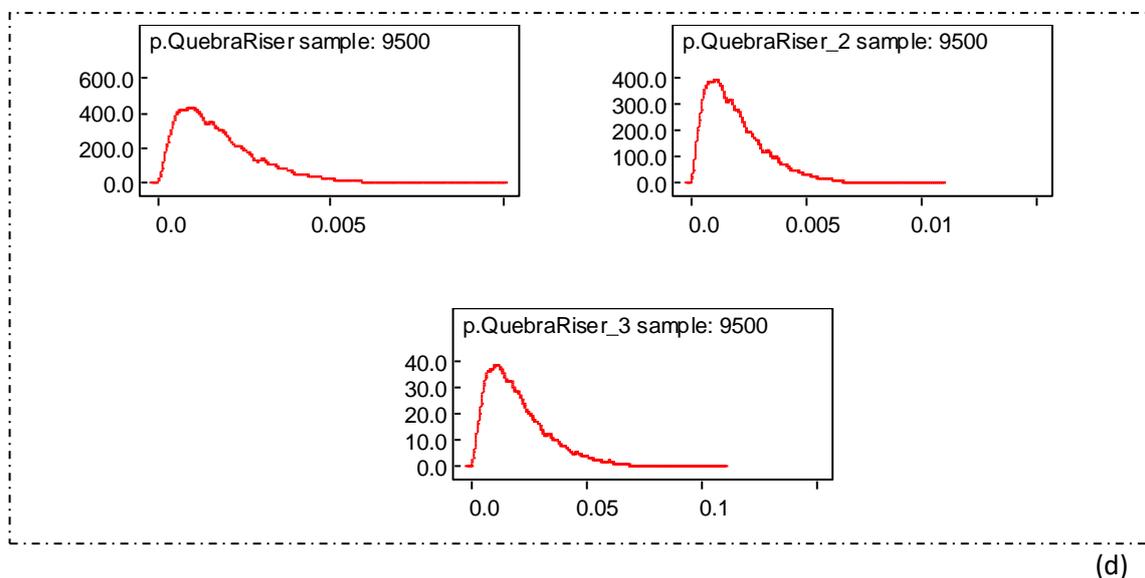
**Gráfico 4:** Gráficos o das consequências e o evento C ao longo dos intervalos e (a) Consequência 1, (b) Consequência 2, (c) Consequência 3 e Evento Quebra de Riser (d)



(b)



(c)



(d)

**Fonte:** A autora (2023)

Ao realizar a comparação das probabilidades entre a hipótese 1 e a hipótese 3, utilizando o valor da média, é percebido que os resultados do caso sem incerteza (caso 1) são menores do que da hipótese 3, o que demonstra que os dados de alto nível geram valores associados as evidências, visto que houve uma ocorrência em um período longo de tempo de 9 anos com 43 acidentes. O mesmo ocorre quando há a comparação entre os valores da média da hipótese 2 com a hipótese 4, em que é adicionado a incerteza ao processo e as evidências, essa diferenciação gerada representa a propagação da incerteza nos valores das probabilidades de ocorrência das consequências e da quebra de *riser*. Para a comparação das hipóteses 3 e 4, em que a diferenciação está na adição da dinâmica ao processo de análise, os valores de 95% obtidos na hipótese 4 são menores,

o que permite concluir que com as inspeções realizadas os valores das probabilidades de falha da quebra de *riser* e da ocorrência das consequências são menores quando não há inspeção.

Portanto, a partir dos resultados gerados com as combinações de opinião de especialistas e dados de alto nível no modelo bayesiana hierárquico com a rede bayesiana dinâmica, percebeu que os valores encontrados são maiores quando comparados aos estáticos por causa das evidências. No caso a dinâmica fosse adicionada ao processo com incerteza, a probabilidade de falha é menor por causa das inspeções. Essas informações obtidas fornece uma referência para tomada de decisões de risco nas operações de perfuração com o *riser*.

Por conseguinte, esses valores encontrados fazem uma previsão de falha para cada um dos cenários de falha das barreiras considerando o evento indesejado, o que proporciona ter uma expectativa sobre o momento de se realizar as manutenções e melhor gerenciamento das ações. Além de colaborar na avaliação de risco da operação de perfuração e controlá-los.

## 6 CONCLUSÃO

O gerenciamento de segurança define os requisitos essenciais e os padrões de segurança apoiados em normas regulamentadoras com a finalidade de prevenir acidentes em operações de alto risco. Esse gerenciamento iniciasse pela identificação e tratamento do risco através de métodos de análise com o objetivo de dar suporte as tomadas de decisões para ações operacionais e de manutenção. Para os cenários com sistemas de alta redundância e confiabilidade, poucas são as informações existentes sobre a falha desses sistemas, o que conduz a uma coleta de dados em fontes variadas e a necessidade do uso de opinião de especialistas agregando incerteza ao processo de estimação da probabilidade de falha do sistema. Além disso, a ausência de dados permite uma desatualização dos parâmetros de confiabilidade dos componentes/sistemas que são causadores de um evento indesejado. Em meio esse cenário, foi modelado uma metodologia de *bowtie* dinâmico combinando rede bayesiana dinâmica e modelagem bayesiana hierárquica com o objetivo de estimar as probabilidades de ocorrência das consequências a partir de um evento indesejado com poucas informações e dados oriundos de fontes variadas e com propagação de incerteza.

A modelagem da proposta metodológica consistiu em onze etapas, em que o cálculo da probabilidade de falha do evento indesejado e das barreiras de segurança presente na estrutura do *bowtie* foi convertida em uma rede bayesiana dinâmica combinada com a modelagem bayesiana hierárquica que permitiu a propagação de incerteza gerada pelos dados oriundos de opiniões de especialistas e dados de alto nível. Os dados de alto nível foram representadas por uma distribuição binomial e os eventos básicos por uma distribuição lognormal com as informações proveniente de especialistas. A estimativa das probabilidades de ocorrência das consequências foi calculada considerando a propagação de incerteza dissipada pela ocorrência do evento indesejado e pelas barreiras de segurança seguindo a técnica de rede bayesiana e árvore de evento. Além dessas estimativas, foi possível atualizar os parâmetros existentes sobre os eventos básicos.

Para o caso de aplicação, com o aumento da demanda de petróleo e gás no mundo, as empresas desse setor investem no desenvolvimento em regiões com poços profundos e ultra profundos. Para isso, houve a necessidade de investir em equipamentos de alta tecnologias e avanços estruturais para as operações de perfuração. O equipamento que foi impactado com esse aumento da profundidade foi o *riser* de perfuração já que sofre

influência das intensas cargas de pressão devido ao aumento da coluna de água. Em grandes profundidades, o *riser* pode sofrer deformações e tensões que causam modificações em sua estrutura como fadigas e corrosões, além da movimentação da plataforma dado a interferência do mar, que pode permitir a sua desconexão. Essas causas geram a quebra ou fratura do *riser*, um acidente altamente custoso e perigoso para a unidade da sonda e ao meio ambiente. Esse equipamento pertence ao cenário de análise considerado com poucos dados de falha dos equipamentos e relevância no estudo do risco, visto seu impacto financeiro e ambiental. Foi aplicado a incerteza a esse caso com a consideração da opinião de especialistas, e dados de alto nível com as evidências, para gerar resultados que servem de embasamento quantitativo de análise de risco para as tomadas de decisões da gerência com a finalidade de manter a integridade do poço por meio de planos de manutenção adequados.

Diferente das abordagens encontradas na pesquisa bibliográfica realizada e após a comparação desses resultados encontrados ao aplicar essa proposta com os casos de *bowtie* estático, esse modelo metodológico proporciona um resultado de probabilidade mais adequado as evidências existentes e menor quando comparado a casos em que não há consideração de incerteza e dados de alto nível. Assim, essa tese teve por finalidade apresentar a modelagem de uma proposta metodológica para gerar valores mais realistas sobre as probabilidades de ocorrência das consequências de um evento indesejado por meio de um *bowtie* dinâmico considerando as incertezas dos dados.

A limitação desta tese está associada a não consideração do processo de reparo do sistema voltando ao funcionamento. Isso pode ser avançado ao considerar um reparo perfeito e imperfeito. Outros avanços a ser considerado são a inclusão de estados de degradação nos eventos/componentes e a utilização de outro processo de análise dinâmica. Sendo essas condições possíveis para trabalhos futuros.

## REFERÊNCIA BIBLIOGRÁFICA

ABIMBOLA, M.; KHAN, F.; KHAKZAD, N.; BUTT, S. Safety and risk analysis of managed pressure drilling operation using Bayesian network. **Safety science**, v. 76, p. 133–144, 2015.

ABIMBOLA, M.; KHAN, F.; KHAKZAD, N. Dynamic safety risk analysis of offshore drilling. **Journal of Loss Prevention in the Process Industries**, v. 30, n. 1, p. 74–85, 2014. Doi:10.1016/j.jlp.2014.05.002.

ACHUMBA, I. E.; AZZI, D.; OPARA, F. K.; BERSCH, S.; EZEBILI, I. On Selecting the Optimal Bayesian Network Model Construction Approach. **Proceedings of the World Congress on Engineering**, v. II, 2012.

ADUMENE, S.; KHAN, F.; ADEDIGBA, S.; ZENDEHBOUND, S. Dynamic risk analysis of marine and offshore systems suffering microbial induced stochastic degradation. **Reliability Engineering and System Safety**, v. 207, 2021. DOI: 10.1016/j.ress.2020.107388.

AHMED, A.; HOSSAIN, M. S.; PANDEY, P.; SAPKOTA, A.; THIAN, B. Deformation modeling of flexible pavement in expansive subgrade in texas. **Geosciences**, v. 9, n. 10, p. 446. 2019.

AICHE. **Guidelines for Chemical Process Quantitative Risk Analysis**. 2nd edition. New York: AIChE, 2000.

AMERICAN PETROLEUM INSTITUTE. API RP 16Q – **Recommended Practice for Design, Selection, Operation and Maintenance of Marine Drilling Riser Systems**. 1993

AMERICAN PETROLEUM INSTITUTE (API), API STD 53 **Well Control Equipment Systems for Drilling Wells**, Washington, DC: API Publishing Services, 2018.

AMIN, T.; KHAN, F.; IMTIAZ, S. Dynamic availability assessment of safety critical systems using a dynamic Bayesian network. **Reliability Engineering & System Safety**, v. 178, n. April, p. 108–117, 2018.

AMIN, Md Tanjin et al. A data-driven Bayesian network learning method for process fault diagnosis. **Process Safety and Environmental Protection**, v. 150, p. 110-122, 2021

ANDRADE, A. R.; TEIXEIRA, P. F. Statistical modelling of railway track geometry degradation using hierarchical Bayesian models. **Reliab. Eng. Syst. Saf.**, v. 142, p. 169–183, 2015.

ANDREWS, J.; FECAROTTI, C. System design and maintenance modelling for safety in extended life operation. **Reliability Engineering and System Safety**, v. 163, p. 95–108, 2017. Doi:10.1016/j.ress.2017.01.024.

ANP. **Subsea accidents data ANP protocol 48003.007351/2021-81**. 2021 (accessed 2.2.22). <https://falabr.cgu.gov.br/publico/Manifestacao/SelecionarTipoManifestacao.aspx?ReturnUrl=%2f>.

APOSTOLAKIS, G.; KAPLAN, S.; GARRICK, B. J.; DUPHIPLY, R. J. Data specialization for plant specific risk studies. **Nuclear Engineering and Design**, v. 56, n. 2, p. 321-329, 1980.

ARAÚJO, J. B.; FERNANDES, A. C.; JR, J. S. S.; THURLER, A. C.; VILELA, A. M.

Innovative oil offloading system for deep water. In: **Offshore Technology Conference**, OTC, 2019.

ARZAGHI, E.; ABAEI, M. M.; ABBASSI, R.; GARANIYA, V.; BINNS, J.; CHIN, C.; KHAN, F. A hierarchical Bayesian approach to modelling fate and transport of oil released from subsea pipelines. *Process Safety and Environmental Protection*, v. 118, p. 307-315, 2018.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **Confiabilidade e manutenibilidade**: NBR ISO 5462. Rio de Janeiro, 1994.

AVEN, T.; JENSEN, U. (Ed.). **Stochastic models in reliability**. New York, NY: Springer New York, 1999.

BABALEYE, A.; KHORASANCHI, M.; KURT, R. E. Dynamic risk assessment of decommissioning offshore jacket structures. In: INTERNATIONAL CONFERENCE ON OCEAN, OFFSHORE AND ARCTIC ENGINEERING, 37, 2018. **Anais...** [S.l.]: ASME, 2018.

BAI, Y.; BAI, Q. **Subsea Engineering Handbook**. 2nd ed. Gulf Professional Publishing, 2010. DOI: 10.1016/c2016-0-03767-1.

BARALDI, P.; PODOFILLINI, L.; MKRTCHYAN, L.; ZIO, E.; DANG, V. N. Comparing the treatment of uncertainty in Bayesian networks and fuzzy expert systems used for a human reliability analysis application. **Reliability Engineering and System Safety**, v. 138, p. 176–193, 2015. DOI: 10.1016/j.ress.2015.01.016.

BARUA, S.; GAO, X.; PASMANN, H.; MANNAN, M. S. Bayesian network based dynamic operational risk assessment. **Journal of Loss Prevention in the Process Industries**, v. 41, p. 399–410, 2016. DOI: 10.1016/j.jlp.2015.11.024.

BAUDRIT, C., WUILLEMIN, P. H., & PERROT, N. (2013). **Parameter elicitation in probabilistic graphical models for modelling multi-scale food complex systems**. *Journal of food engineering*, 115(1), 1-10.

BEARFIELD, G., MARSH, W. Generalising Event Trees Using Bayesian Networks with a Case Study of Train Derailment. **Computer Safety, Reliability, and Security**, v. 3688 p. 52–66, 2005.

BERNITSAS, Michael M. A three-dimensional nonlinear large-deflection model for dynamic behavior of risers, pipelines, and cables. **Journal of Ship Research**, v. 26, n. 01, p. 59-64, 1982.

BHARDWAJ, U.; TEIXEIRA, A. P.; SOARES, C. G. Bayesian framework for reliability prediction of subsea processing systems accounting for influencing factors uncertainty. **Reliability Engineering & System Safety**, v. 218, p. 108-143, 2022.

BHUWALKA, K., CHOI, E., MOORE, E. A., ROTH, R., KIRCHAIN, R. E., & OLIVETTI, E. A. (2023). A hierarchical Bayesian regression model that reduces uncertainty in material demand predictions. *Journal of Industrial Ecology*, 27(1), 43-55.

BOBBIO, A.; PORTINALE, L.; MINICHINO, M.; CIANCAMERLA, E.. Improving the analysis of dependable systems by mapping fault trees into Bayesian networks. **Reliability Engineering & System Safety**, v. 71, n. 3, p. 249–260, 2001.

BOUISSOU, M.; MARTIN, F.; OURGHANLIAN, A. Assessment of a safety-critical system

including software: a Bayesian belief network for evidence sources. 1999. **Anais** [...] [S.I.], IEEE, 1999. p. 142–150.

BROCCARDO, M.; MIGNAN, A.; WIEMER, S.; STOJADINOVIC, B.; GIARDINI, D. Hierarchical Bayesian modeling of fluid-induced seismicity. **Geophysical Research Letters**, v. 44, n. 22, p. 11,357–11,367, 2017.

BUKOWSKI, J. V. and VAN BEURDEN, I. **Impact of proof test effectiveness on safety instrumented system performance**. In Reliability and Maintainability Symposium, 2009. RAMS. 2009. Annual, pages 157–163. IEEE.

CADINI, F.; GIOLETTA, A. A Bayesian Monte Carlo-based algorithm for the estimation of small failure probabilities of systems affected by uncertainties. **Reliability Engineering & System Safety**, v. 153, p. 15–27, 2016.

CAI, B.; KONG, X.; LIU, Y.; LIN, J.; YUAN, X.; XU, H.; JI, R.. Application of Bayesian Networks in Reliability Evaluation. **IEEE Transactions on Industrial Informatics**, v. 15, n. 4, p. 2146–2157, 2019. DOI: 10.1109/TII.2018.2858281.

CAI, B.; LIU, Y.; FAN, Q.; ZHANG, Y.; LIU, Z.; YU, S.; JI, R. Multi-source information fusion based fault diagnosis of ground-source heat pump using Bayesian network. **Applied Energy**, v. 114, p. 1–9, 2014.

CAI, B.; LIU, Y.; FAN, Q.; ZHANG, Y.; YU, S.; LIU, Z.; DONG, X. Performance evaluation of subsea BOP control systems using dynamic Bayesian networks with imperfect repair and preventive maintenance. **Engineering Applications of Artificial Intelligence**, v. 26, n. 10, p. 2661–2672, 2013a. DOI: 10.1016/j.engappai.2013.08.011.

CAI, B.; LIU, Y.; LIU, Z.; TIAN, X.; ZHANG, Y.; LIU, J. Performance evaluation of subsea blowout preventer systems with common-cause failures. **Journal of Petroleum Science and Engineering**, v. 90–91, p. 18–25, 2012a. DOI: 10.1016/j.petrol.2012.04.007.

CAI, B.; LIU, Y.; LIU, Z.; TIAN, X.; LI, H.; REN, C. Reliability analysis of subsea blowout preventer control systems subjected to multiple error shocks. **Journal of Loss Prevention in the Process Industries**, v. 25, n. 6, p. 1044–1054, 2012b. DOI: 10.1016/j.jlp.2012.07.014.

CAI, B.; LIU, Y.; LIU, Z.; TIAN, X.; DONG, X.; YU, S. Using Bayesian networks in reliability evaluation for subsea blowout preventer control system. **Reliability Engineering & System Safety**, v. 108, p. 32–41, 2012c.

CAI, B.; LIU, Y.; MA, Y.; LIU, Z.; ZHOU, Y.; SUN, J.. Real-time reliability evaluation methodology based on dynamic Bayesian networks: A case study of a subsea pipe ram BOP system. **ISA Transactions**, v. 58, p. 595–604, 2015. DOI: 10.1016/j.isatra.2015.06.011.

CAI, B.; LIU, Y.; XIE, M. A dynamic-bayesian-network-based fault diagnosis methodology considering transient and intermittent faults. **IEEE Transactions on Automation Science and Engineering**, v. 14, n. 1, p. 276–285, 2017. DOI: 10.1109/TASE.2016.2574875.

CAI, B.; LIU, Y.; ZHANG, Y.; FAN, Q.; LIU, Z.; TIAN, X. A dynamic Bayesian networks modeling of human factors on offshore blowouts. **Journal of Loss Prevention in the Process Industries**, v. 26, n. 4, p. 639–649, 2013b. DOI: 10.1016/j.jlp.2013.01.001.

CAI, B.; LIU, Y.; ZHANG, Y.; FAN, Q.; YU, S. Dynamic Bayesian networks based performance evaluation of subsea blowout preventers in presence of imperfect repair. **Expert Systems with Applications**, v. 40, n. 18, p. 7544–7554, 2013c. DOI:

10.1016/j.eswa.2013.07.064.

CAI, B., Zhang, Y., Wang, H., Liu, Y., Ji, R., Gao, C., ... & Liu, J. (2021). **Resilience evaluation methodology of engineering systems with dynamic-Bayesian-network-based degradation and maintenance**. *Reliability Engineering & System Safety*, 209, 107464.

CAI, B., Shao, X., Liu, Y., Kong, X., Wang, H., Xu, H., & Ge, W. (2019). **Remaining useful life estimation of structure systems under the influence of multiple causes: Subsea pipelines as a case study**. *IEEE Transactions on Industrial Electronics*, 67(7), 5737-5747.

CAI, B.; LIU, Y.; FAN, Q. A multiphase dynamic Bayesian networks methodology for the determination of safety integrity levels. **Reliability Engineering & System Safety**, v. 150, p. 105-115. 2016.

CELEUX, G.; CORSET, F.; LANNOY, A. Designing a Bayesian network for preventive maintenance from expert opinions in a rapid and reliable way. **Reliability Engineering & System Safety**, v. 91, n. 7, p. 849–856, 2006.

CHANG, Y.; CHEN, G.; WU, X.; YE, J.; CHEN, B.; XU, L. Failure probability analysis for emergency disconnect of deepwater drilling riser using bayesian network. **J. Loss Prev. Process. Ind.**, v. 51, p. 42–53, 2018a.

CHANG, Y.; WU, X.; ZHANG, C.; CHEN, G.; LIU, X.; LI, J.; CAI, B.; XU, L. Dynamic Bayesian networks based approach for risk analysis of subsea wellhead fatigue failure during service life. **Reliability Engineering and System Safety**, v. 188, p. 454-462, 2019. DOI: 10.1016/j.res.2019.03.040.

CHANG, Y.; WU, X.; CHEN, G.; YE, J.; CHEN, B.; XU, L.; ZHOU, J.; YIN, Z.; REN, K. Comprehensive risk assessment of deepwater drilling riser using fuzzy Petri net model. **Process Saf. Environ. Protect.**, v. 117, p. 483–497, 2018b.

CHANG, Y., Wu, X., Zhang, C., Chen, G., Liu, X., Li, J., ... & Xu, L. (2019). **Dynamic Bayesian networks based approach for risk analysis of subsea wellhead fatigue failure during service life**. *Reliability Engineering & System Safety*, 188, 454-462.

CHAMBON, S.; VENKATAKRISHNAN, S.; HAMZAH, M. K.; BELASKIE, J.; YU, Y. Real-Time Well Construction Process Inference through Probabilistic Data Fusion. In: **SPE/IADC Drilling Conference and Exhibition**, 2018.

CHAZE, X.; NAPOLI, A. Causal Probabilistic Modeling with Bayesian Networks to Combat the Risk of Piracy Against Offshore Oil Platforms. **Role of Radio Science in Disaster Management**, v. 345, n. 345, p. 21–34, 2013.

CHEN, S. H.; POLLINO, C. A. Good practice in Bayesian network modelling. **Environmental Modelling and Software**, v. 37, p. 134–145, 2012. DOI: 10.1016/j.envsoft.2012.03.012.2018.

COLE, P. V. Z. A Bayesian reliability assessment of complex systems for binomial sampling. **IEEE Transactions on Reliability**, v. 24, n. 2, p. 114–117, 1975.

COOPER, G. F. The computational complexity of probabilistic inference using bayesian belief networks. **Artificial Intelligence**, v. 42, n. 2–3, p. 393–405, 1990. DOI: 10.1016/0004-3702(90)90060-D.

COOPER, G. F.; HERSKOVITS, E. A Bayesian Method for the Induction of Probabilistic

Networks from Data. **Machine Learning**, v. 9, n. 4, p. 309–347, 1992. DOI: 10.1023/A:1022649401552.

COOKE, Roger. Experts in uncertainty: opinion and subjective probability in science. **Oxford University Press**, USA, 1991

CRESSIE, N., Calder, C.A., Clark, J.S., Ver Hoef, J.M., Wikle, C.K., 2009. Accounting for uncertainty in ecological analysis: the strengths and limitations of hierarchical statistical modeling. *Ecol. Appl.* 19 (3), 553–570. <https://doi.org/10.1890/07-0744.1>.

DABROWSHI, J. J., & De Villiers, J. P. (2015). **A unified model for context-based behavioural modelling and classification**. *Expert Systems with Applications*, 42(19), 6738–6757.

DARDENO, T. A., WORDEN, K., DERVILIS, N., MILLS, R. S., & BULL, L. A. (2024). On the hierarchical Bayesian modelling of frequency response functions. *Mechanical Systems and Signal Processing*, 208, 111072.

DEDECIUS, K.; ETTLER, P. Hierarchical modelling of industrial system reliability with probabilistic logic. **ICINCO 2014 - Proceedings of the 11th International Conference on Informatics in Control, Automation and Robotics**, v. 1, p. 133–139, 2014. DOI: 10.5220/0005007001330139.

DEDECIUS, K.; NAGY, I.; KÁRNÝ, M. Parameter tracking with partial forgetting method. **International Journal of Adaptive Control and Signal Processing**, v. 26, n. 1, p. 1–12, 2012.

DEGROOT, M. H.; SCHERVISH, M. J. Probability and statistics. **Pearson Education**, v. 19, p. 33, 2012.

DE MELLO, V. L.; LUPINACCI, W. M. Mineralogy based classification of carbonate rocks using elastic parameters: A case study from Buzios Field. **Journal of Petroleum Science and Engineering**, v. 209, 109962, 2022.

DI MAIO, F.; ANTONELLO, F.; ZIO, E. Condition-based probabilistic safety assessment of a spontaneous steam generator tube rupture accident scenario. **Nuclear Engineering and Design**, v. 326, p. 41–54, 2018.

DROGUETT, E. L.; GROEN, F.; MOSLEH, A. The combined use of data and expert estimates in population variability analysis. **Reliability Engineering & System Safety**, v. 83, n. 3, p. 311–321, 2004.

DROGUETT, E. L.; MOURA, M. das C.; JACINTO, C. M.; SILVA JR., M. F. A semi-Markov model with Bayesian belief network based human error probability for availability assessment of downhole optical monitoring systems. **Simulation Modelling Practice and Theory**, v. 16, n. 10, p. 1713–1727, 2008. DOI: 10.1016/j.simpat.2008.08.011.

DROGUETT, E. L.; SANTOS, W. B. dos; JACINTO, C. M.; SOTOMAYOR, G.; GARCIA, P. A. Reliability assessment of offshore oil multilateral wells in Brazil. **IEEE**, 2006. p. 499–505, 2006.

DRUMOND, G. P.; PASQUALINO, I. P.; PINHEIRO, B. C.; ESTEFEN, S. F. Pipelines, risers and umbilicals failures: A literature review. **Ocean Engineering**, v. 148, p. 412–425, 2018.

DUIM, Fernanda A. C. **Uso de informações de alto nível e opinião de especialistas para estimativa do fator de cobertura numa modelagem via redes bayesianas dinâmicas**. 2017.

Dissertação (Mestrado em Engenharia de Produção) - Universidade Federal Fluminense, Niterói, 2017.

FAN, L.-M.; JIA, L.-L.; REN, Y.; WANG, K.-S.; YANG, A.-Z. Risk Analysis of Discrete Dynamic Event Tree Based on Dynamic Bayesian Network. **Proceedings of 2019 International Conference on Quality, Reliability, Risk, Maintenance, and Safety Engineering, QR2MSE 2019**, p. 141–147, 2019. DOI: 10.1109/QR2MSE46217.2019.9021120.

Fakhravar, D., Khakzad, N., Reniers, G., & Cozzani, V. Security vulnerability assessment of gas pipelines using Discrete-time Bayesian network. **Process Safety and Environmental Protection**, 111, 714-725, 2017.

FIGUEREDO, A. K. M.; COELHO, D. G.; MIRANDA, P. P.; SOUZA JUNIOR, M. B. de; MELO, P. F. F. F.; VAZ JUNIOR, C. A. Subsea pipelines incidents prevention: A case study in Brazil. **Journal of Loss Prevention in the Process Industries**, v. 83, p. 105007, 2023.

GAO, C.; GUO, Y.; ZHONG, M.; LIANG, X.; WANG, H.; YI, H. Reliability analysis based on dynamic Bayesian networks: A case study of an unmanned surface vessel. **Ocean Engineering**, v. 240, 109970, 2021.

GELMAN, A. (2006). Multilevel (hierarchical) modeling: What it can and cannot do. *Technometrics*, 48(3), 432–435. <https://doi.org/10.1198/004017005000000661>

GRAN, B. A.; HELMINEN, A. A Bayesian belief network for reliability assessment. **Springer**, p. 35-45, 2001.

GUAN, X.; HE, J.; JHA, R.; LIU, Y. An efficient analytical Bayesian method for reliability and system response updating based on Laplace and inverse first-order reliability computations. **Reliability Engineering & System Safety**, v. 97, n. 1, p. 1–13, 2012.

GUI, M.; SUI, Y.; DING, R.; XING, S.; YU, T.; XU, J.; YANG, B.; MENG, F. An Approach for the Dynamic Reliability Assessment of the Digital Power Control System for Nuclear Reactor. **Frontiers in Energy Research**, v. 10, p. 877-933, 2022.

HADDAD, S.; DUBUS, S.; HECKER, A.; KANSTRÉN, T.; MARQUET, B.; SAVOLA, R. Operational security assurance evaluation in open infrastructures. **IEEE**, p. 1–6, 2011.

HAMADA, M. S.; WILSON, A. G.; REESE, C. S.; MARZ, H. F. **Bayesian reliability**. New York: Springer, 2008.

HÄNNINEN, Maria. Bayesian networks for maritime traffic accident prevention: Benefits and challenges. **Accident Analysis & Prevention**, v. 73, p. 305-312, 2014.

HUANG, C. L., Shih, H. C., & Chao, C. Y. (2006). **Semantic analysis of soccer video using dynamic Bayesian network**. *IEEE Transactions on Multimedia*, 8(4), 749-760.

HAVIARAS, G. J. **Metodologia para análise de confiabilidade de pneus radiais em frotas de caminhões de longa distância**. [S.l.], Universidade de São Paulo, 2005.

HECKERMAN, D.; MAMDANI, A.; WELLMAN, M. P. Real-world applications of Bayesian networks. **Communications of the ACM**, v. 38, n. 3, p. 24–26, 1995.

HEINS, W. A.; O'GRADY, D. B.; ARDIÇ, C. Integrated genetic analysis of sediment generation and evolution to predict basin-scale clastic reservoir/seal distribution and character.

**International Petroleum Technology Conference, IPTC**, v. 3, p. 1579–1585, 2008. DOI: 10.3997/2214-4609-pdb.148.iptc12420.

HENG, J.; ZHENG, K.; KAEWUNRUEN, S.; ZHU, J.; BANIOPOULOS, C. Dynamic Bayesian network-based system-level evaluation on fatigue reliability of orthotropic steel decks. **Engineering Failure Analysis**, v. 105, p. 1212-1228, 2019.

HOLAND, Per. Reliability of deepwater subsea blowout preventers. **SPE Drilling & Completion**, v. 16, n. 01, p. 12-18, 2001.

HONG, E.-S.; LEE, I.-M.; SHIN, H.-S.; NAM, S.-W.; KONG, J.-S. Quantitative risk evaluation based on event tree analysis technique: Application to the design of shield TBM. **Tunnelling and Underground Space Technology**, v. 24, n. 3, p. 269–277, 2009.

HONG, B.; SHAO, B.; GUO, J.; FU, J.; LI, C.; ZHU, B. Dynamic Bayesian network risk probability evolution for third-party damage of natural gas pipelines. **Applied Energy**, v. 333, 2023.

HOSSEINI, S.; AL KHALED, A.; SARDER, M. D. A general framework for assessing system resilience using Bayesian networks: A case study of sulfuric acid manufacturer. **Journal of Manufacturing Systems**, v. 41, p. 211–227, 2016. DOI: 10.1016/j.jmsy.2016.09.006.

HU, J.; ZHANG, L.; MA, L.; LIANG, W. An integrated safety prognosis model for complex system based on dynamic Bayesian network and ant colony algorithm. **Expert Systems with Applications**, v. 38, n. 3, p. 1431–1446, 2011.

IEC-61508 **Functional safety of electrical/electronic/programmable electronic safety related systems: Parts 1 - 7**. 2009

IEC-61511. **Functional safety—safety instrumented systems for the process industry, parts 1 - 3**. 2014.

ISA-TR84.00.0. **Guidance for testing of process sector safety instrumented functions (sif) implemented as or within safety instrumented systems (sis)**.2022

ISO. 13624-2, **Petroleum and Natural Gas Industries – Drilling and Production Equipment – Part 2: Deepwater Drilling Riser Methodologies, Operations, and Integrity Technical Report**. 2010.

JACOBS, J. A.; FRICKEL, Scott. Interdisciplinarity: A critical assessment. **Annual review of Sociology**, v. 35, p. 43-65, 2009.

JAFARI, M.; BROWN, L. E.; GAUCHIA, L. Título do artigo. **IEEE Transactions on Transportation Electrification**, v. 5, n. 4, p. 1254-1267, 2019.

JENSEN, F. V. **An introduction to Bayesian networks**. [S.l.]: UCL press London, 1996. v. 210.

JI, J.; TONG, Q.; KHAN, F.; DADASHZADEH, M.; ABBASSI, R. Risk-based domino effect analysis for fire and explosion accidents considering uncertainty in processing facilities. **Industrial & Engineering Chemistry Research**, v. 57, n. 11, p. 3990-4006, 2018.

JIA, L.; REN, Y.; YANG, D.; FENG, Q.; SUN, B.; QIAN, C. Reliability analysis of dynamic reliability block diagram based on dynamic uncertain causality graph. **Journal of Loss Prevention in the Process Industries**, v. 62, 103947, 2019.

JIANG, Y.; ZHANG, H.; SONG, X.; JIAO, X.; HUNG, W. N. N.; GU, M.; SUN, J. Bayesian-network-based reliability analysis of PLC systems. **IEEE Transactions on Industrial Electronics**, v. 60, n. 11, p. 5325–5336, 2012.

JIN, Y. A. N. G. Calculation method of surface conductor setting depth in deepwater oil and gas wells. **Acta Petrolei Sinica**, v. 40, n. 11, p. 1396, 2019.

KABIR, S.; PAPADOPOULOS, Y. Applications of Bayesian networks and Petri nets in safety, reliability, and risk assessments: A review. **Safety Science**, v. 115, p. 154–175, June 2019. DOI: 10.1016/j.ssci.2019.02.009.

KABIR, S.; TALEB-BERROUANE, M.; PAPADOPOULOS, Y. Dynamic reliability assessment of flare systems by combining fault tree analysis and Bayesian networks. **Energy Sources, Part A: Recovery, Utilization, and Environmental Effects**, v. 45, n. 2, p. 4305-4322, 2023.

KANES, R.; MARENGO, M. C. R.; ABDEL-MOATI, H.; CRANFIELD, J.; VÉCHOT, L. Developing a framework for dynamic risk assessment using Bayesian networks and reliability data. **Journal of Loss Prevention in the Process Industries**, v. 50, p. 142–153, 2017.

KELLY, D. L.; SMITH, C. L. Bayesian inference in probabilistic risk assessment-The current state of the art. **Reliability Engineering and System Safety**, v. 94, n. 2, p. 628–643, 2009. DOI: 10.1016/j.ress.2008.07.002.

KELLY, D. L.; SMITH, C. L. **Bayesian inference for probabilistic risk assessment: A practitioner's guidebook**. [S.l.]: Springer Science & Business Media, 2011.

KHAKZAD, N.; KHAN, F.; AMYOTTE, P. Dynamic safety analysis of process systems by mapping bow-tie into Bayesian network. **Process Safety and Environmental Protection**, v. 91, n. 1–2, p. 46–53, 2013.

KHAKZAD, N.; KHAN, F.; AMYOTTE, P. Risk-based design of process systems using discrete-time Bayesian networks. **Reliability Engineering and System Safety**, v. 109, p. 5–17, 2013b. DOI: 10.1016/j.ress.2012.07.009.

KHAKZAD, N.; KHAN, F.; AMYOTTE, P. Safety analysis in process facilities: Comparison of fault tree and Bayesian network approaches. **Reliability Engineering & System Safety**, v. 96, n. 8, p. 925–932, 2011.

KHAKZAD, Nima; KHAN, Faisal; AMYOTTE, Paul. Dynamic risk analysis using bow-tie approach. **Reliability Engineering & System Safety**, v. 104, p. 36-44, 2012.

KIM, M. C. Reliability block diagram with general gates and its application to system reliability analysis. **Annals of Nuclear Energy**, v. 38, n. 11, p. 2456–2461, 2011.

KIRTON, B.; WULF, G.; HENDERSON, B. Thunder horse drilling riser break-The road to recovery. *In: SPE Annual Technical Conference and Exhibition*. Society of Petroleum Engineers, 2004.

KLOOS, M., PESCHKE, J. MCDT: A Probabilistic Dynamics Method Combining Monte Carlo Simulation with the Discrete Dynamic Event Tree Approach. **Nuclear science and engineering**, v. 153, n. 2, p. 137–156, 2006.

KONG, X.; XIAO, J.; LIU, D.; WU, J.; WANG, C.; SHEN, Y. Robust stochastic optimal

dispatching method of multi-energy virtual power plant considering multiple uncertainties. **Applied Energy**, v. 279, 2020.

KOHLER, D., Marzouk, Y. M., Müller, J., & Wever, U. (2015). **A new network approach to Bayesian inference in partial differential equations**. *International Journal for Numerical Methods in Engineering*, 104(5), 313-329.

KWON, Y.; WON, J.-H.; JOON, B. J.; PAIK, M. C. Uncertainty quantification using Bayesian neural networks in classification: Application to biomedical image segmentation. **Computational Statistics & Data Analysis**, v. 142, 2020.

LABATUT, V., Pastor, J., Ruff, S., Démonet, J. F., & Celsis, P. (2004). **Cerebral modeling and dynamic Bayesian networks**. *Artificial Intelligence in Medicine*, 30(2), 119-139

LAMPIS, M.; ANDREWS, J. Bayesian Belief Networks for System fault Diagnostics. **Quality and Reliability Engineering International**, v. 25, p. 409–426, 2009. DOI: 10.1002/qre.

LANG, D. W.; REAL, J.; LANE, M. Recent developments in drilling riser disconnect and recoil analysis for deepwater applications. *In: International Conference on Offshore Mechanics and Arctic Engineering*. 2009. p. 305-318.

LEE, D.; CHOI, D. Analysis of the reliability of a starter-generator using a dynamic Bayesian network. **Reliability Engineering and System Safety**, v. 195, 2020. DOI: 10.1016/j.ress.2019.106628.

LEONI, C.; MAJORANI, C.; FAMELE, M.; FERRANTI, C.; LAVALLE, R.; ABENAVOLI, C.; POLCI, M. L.; PALLESCHI, L.; FAVA, L.; FIDENTE, R. M.; D'ILIO, S.; DRAISCI, R.. Validation and measurement uncertainty evaluation of a GC/MS method for the quantification of nine phthalates in tattoo and PMU inks. **Accreditation and Quality Assurance**, v. 26, p. 249-260, 2021.

LEWIS, E. E. **Introduction to reliability engineering**. [S.l: s.n.], 1987.

LI, Xinhong; CHEN, Guoming; ZHU, Hongwei. Quantitative risk analysis on leakage failure of submarine oil and gas pipelines using Bayesian network. **Process Safety and Environmental Protection**, v. 103, p. 163-173, 2016.

LI, H.; HUANG, H.-Z.; LI, Y.-F.; ZHOU, J.; MI, J. Physics of failure-based reliability prediction of turbine blades using multi-source information fusion. **Applied Soft Computing**, v. 72, p. 624–635, 2018.

LI, Yuling; GULDENMUND, Frank W. Safety management systems: A broad overview of the literature. **Safety science**, v. 103, p. 94-123, 2018.

LI, M.; FU, Q.; SINGH, V. P.; LIU, D.; LI, T.; ZHOU, Y. Managing agricultural water and land resources with tradeoff between economic, environmental, and social considerations: A multi-objective non-linear optimization model under uncertainty. **Agricultural systems**, v. 178, 102685, 2020.

LI, X.; CHEN, G.; KHAN, F.; XU, C. Dynamic risk assessment of subsea pipelines leak using precursor data. **Ocean Engineering**, v. 178, p. 156–169, 2019. DOI: 10.1016/j.oceaneng.2019.02.009.

LI, X.-T.; TAO, L.-M.; JIA, M. A Bayesian networks Approach for event tree time-dependency Analysis on phased-mission system. **Eksploracja i Niezawodność**, v. 17, n. 2, p.

273–281, 2015. DOI: 10.17531/ein.2015.2.15.

LI, Y. F.; HUANG, H. Z.; MI, J.; PENG, W.; HAN, X. Reliability analysis of multi-state systems with common cause failures based on Bayesian network and fuzzy probability. **Annals of Operations Research**, p. 1-15.2022.

LIU, H.; SIMONYAN, K.; VINYALS, O.; FERNANDO, C.; KAVUKCUOGLU, K. Hierarchical representations for efficient architecture search. **International Conference on Learning Representations**, 2017.

LIU, K.; HE, N.; ZHANG, Y.; XU, F.; WANG, Y. Safety risk analysis of gas injection and recovery wells in the Xiangguosi Gas Storage and countermeasures. **Nat. Gas. Ind.**, v. 33, p. 131–135, 2013.

LIU, Y.; LIN, P.; LI, Y.; HUANG, H-Z. Bayesian Reliability and Performance Assessment for Multi-State Systems. **IEE**, v. 64, n. 1, p. 394–409, 2015a.

LIU, Z.; LIU, Y.; CAI, B.; ZHANG, D.; ZHENG, C. Dynamic Bayesian network modeling of reliability of subsea blowout preventer stack in presence of common cause failures. **Journal of Loss Prevention in the Process Industries**, v. 38, p. 58–66, 2015b. DOI: 10.1016/j.jlp.2015.09.001.

LIU, Z.; LIU, Y.; CAI, B.; ZHENG, C. Expert Systems with Applications An approach for developing diagnostic Bayesian network based on operation procedures. **Expert Systems With Applications**, v. 42, n. 4, p. 1917–1926, 2015c. DOI: 10.1016/j.eswa.2014.10.020.

Lu, L., Liang, W., Zhang, L., Zhang, H., Lu, Z., & Shan, J. (2015). A comprehensive risk evaluation method for natural gas pipelines by combining a risk matrix with a bow-tie model. **Journal of Natural Gas Science and Engineering**, 25, 124-133.

MAHADEVAN, S.; ZHANG, R.; SMITH, N. Bayesian networks for system reliability reassessment. **Structural Safety**, v. 23, n. 3, p. 231–251, 2001. DOI: 10.1016/S0167-4730(01)00017-0.

MAHBOOB, Q.; STRAUB, D. Comparison of fault tree and Bayesian Networks for modeling safety critical components in railway systems. **Advances in Safety, Reliability and Risk Management - Proceedings of the European Safety and Reliability Conference, ESREL**, p. 89–95, 2012. DOI: 10.1201/b11433-16.

MAITI, S.; GUPTA, G.; ERRAM, V. C.; TIWARI, R. K. Inversion of schlumberger resistivity sounding data from the critically dynamic Koyna region using the hybrid Monte Carlo-based neural network approach. **Nonlinear Processes in Geophysics**, v. 18, n. 2, p. 179–192, 2011. DOI: 10.5194/npg-18-179-2011.

MÄKINEN, Jussi; VANHATALO, Jarno. Hierarchical Bayesian model reveals the distributional shifts of Arctic marine mammals. **Diversity and Distributions**, v. 24, n. 10, p. 1381-1394, 2018.

MAMUDU, A., Khan, F., Zendeheboudi, S., & Adedigba, S. (2020). **A hybrid intelligent model for reservoir production and associated dynamic risks**. *Journal of Natural Gas Science and Engineering*, 83, 103512.

MANNAN, S.; LEES, F. P. **Lee's Loss Prevention in the Process Industries**. HazardrM2. Oxford, U. K: Elsevier Butterworth-Heinemann, 2005.

MARQUEZ, D.; NEIL, M.; FENTON, N. Improved reliability modeling using Bayesian networks and dynamic discretization. **Reliability Engineering & System Safety**, v. 95, n. 4, p. 412–425, 2010.

MARSH, W.; BEARFIELD, G. **Representing parameterised fault trees using Bayesian networks**. [S.l.]: Springer, 2007. p. 120–133.

MARTINO, J. P. The Lognormality of Dephi Estimates. **Technological Forecasting**, v. 1, p. 355-358, 1970.

MARTINS, M. R.; MATURANA, M. C. Application of Bayesian Belief networks to the human reliability analysis of an oil tanker operation focusing on collision accidents. **Reliability Engineering & System Safety**, v. 110, p. 89–109, 2013.

MATSUBA, M., TSUJIMOTO, A., TSUCHUYA, M., TANAKA, Y., & NOMAKI, H. (2023). Effectiveness of hierarchical Bayesian models for citizen science data with missing values: A case study on the factors influencing beach litter in Shimane Prefecture, Japan. *Marine Pollution Bulletin*, 191, 114948.

MENG, D., Yang, S., He, C., Wang, H., Lv, Z., Guo, Y., & Nie, P. (2022). Multidisciplinary design optimization of engineering systems under uncertainty: a review. **International Journal of Structural Integrity**, 13(4), 565-593.

MI, J.; LI, Y.; HUANG, H.-Z.; LIU, Y.; ZHANG, X.-L. R Reliability analysis of multi-state systems with common cause failure based on Bayesian Networks. **IEEE**, 2012. p. 1117–1121.

MICHAILLIDIS, G., & d'Alché-Buc, F. (2013). **Autoregressive models for gene regulatory network inference: Sparsity, stability and causality issues**. *Mathematical biosciences*, 246(2), 326-334.

MIURA, K. **A Study on Safety of Construction and Repair in Offshore Oil and Gas Wells**. Universidade Estadual de Campinas, 2004.

MKRTCHYAN, L.; PODOFILLINI, L.; DANG, V. N. Bayesian belief networks for human reliability analysis: A review of applications and gaps. **Reliability Engineering & System Safety**, v. 139, p. 1–16, 2015.

MOSLEH, A. Bayesian modeling of expert-to-expert variability and dependence in estimating rare event frequencies. **Reliability Engineering & System Safety**, v. 38, n. 1-2, p. 47-57, 1992.

MOSLEH, A.; APOSTOLAKIS, G. **Models for the use of expert opinions**. *Low-Probability High-Consequence Risk Analysis: Issues, Methods, and Case Studies*, p. 107-124, 1984.

MOSLEH, A.; APOSTOLAKIS, G. The assessment of probability distributions from expert opinions with an application to seismic fragility curves. **Risk analysis**, v. 6, n. 4, p. 447-461, 1986.

MOHAMMADI, Mehdi et al. Deep learning for IoT big data and streaming analytics: A survey. **IEEE Communications Surveys & Tutorials**, v. 20, n. 4, p. 2923-2960, 2018.

MURPHY, K. P. **Dynamic Bayesian Networks: Representation, Inference and Learning, dissertation**. PhD thesis, UC Berkley, Dept. Comp. Sci, 2002.

MUSHARRAF, M.; SMITH, J.; KHAN, F.; VEITCH, B.; MACKINNON, S. Assessing offshore emergency evacuation behavior in a virtual environment using a Bayesian Network

approach. **Reliability Engineering and System Safety**, v. 152, p. 28–37, 2016. Disponível em: <http://dx.doi.org/10.1016/j.ress.2016.02.001>. Acesso em:

NEIL, M.; FENTON, N.; LAGNADO, D.; GILL, R. D. Modelling competing legal arguments using Bayesian model comparison and averaging. **Artificial intelligence and law**, v. 27, p. 403–430, 2019.

NEIL, M.; LITTLEWOOD, B.; FENTON, N. Applying Bayesian belief networks to system dependability assessment. **Safety-critical systems: the convergence of high tech and human factors**, [S.l.], p. 71–94, 1996.

NEIL, M.; MARQUEZ, D. Availability modelling of repairable systems using Bayesian networks. **Engineering Applications of Artificial Intelligence**, v. 25, n. 4, p. 698–704, 2012.

NELSON, E.; GUILLOT, D.; CEMENTING, W. **Schlumberger: Sugar Land**. TX, USA, 2006.

NETICA. **Norsys software corporation, Netica version 4.16**. Available at <http://www.norsys.com>. 2010.

NGUYEN, T. C.; AL-SAFRAN, E. Marine riser failure analysis for offshore conventional drilling and managed pressure drilling operations. **Journal of Petroleum Science and Engineering**, v. 199, p. 108307, 2021.

NI, S.; TANG, Y.; WANG, G.; YANG, L.; LEI, B.; ZHANG, Z. Risk identification and quantitative assessment method of offshore platform equipment. *Energy Reports*, v. 8, p. 7219–7229, 2022.

NÝVLT, O.; RAUSAND, M. Dependencies in event trees analyzed by Petri nets. **Reliability Engineering & System Safety**, v. 104, p. 45–57, 2012.

NUCLEAR REGULATORY COMMISSION. **Safety evaluation report related to the operation of Sequoyah Nuclear Plant, Units 1 and 2, Docket Nos. 50-327 and 50-328, Tennessee Valley Authority**. Supplement No. 4. US Nuclear Regulatory Commission, 1981.

OCHENI, Elejo Samuel. **Impact of partial and imperfect testing on reliability assessment of safety instrumented systems-Possible approaches for inclusion of its effects in reliability assessments**. 2015. Dissertação de Mestrado. NTNU.

OREDA (**Offshore Reliability Data Handbook**). SINTEF Industrial Management. DetNorske Veritas, 2002.

PAN, X.; DI MAIO, F.; ZIO, E. A benchmark of dynamic reliability methods for probabilistic safety assessment. **2nd International Conference on System Reliability and Safety, ICSRS 2017**, v. 2018-Janua, n. Mc, p. 82–90, 2016. DOI: 10.1109/ICSRS.2017.8272801.

PANG, N.; JIA, P.; WANG, L.; YUN, F.; WANG, G.; WANG, X.; SHI, L. Dynamic Bayesian network-based reliability and safety assessment of the subsea Christmas tree. **Process Safety and Environmental Protection**, v. 145, p. 435–446, 2021. DOI: 10.1016/j.psep.2020.11.026.

PANG, T. Y.; YU, T. X.; SONG, B. F. Fault diagnosis for mechanical system using dynamic Bayesian network. **IOP Conference Series: Materials Science and Engineering**, v. 1043, n. 3, 2021. DOI: 10.1088/1757-899X/1043/3/032062.

PEARL, J. **Probabilistic Reasoning in Intelligent Systems: Networks of Plausible Inference**.

San Mateo: Morgan Kaufmann, 1988.

PODOFILLINI, L.; DANG, V. N. A Bayesian approach to treat expert-elicited probabilities in human reliability analysis model construction. **Reliability Engineering & System Safety**, v. 117, p. 52–64, 2013.

RAFTERY, A. E.; KÁRNÝ, M.; ETTLER, P. Online prediction under model uncertainty via dynamic model averaging: Application to a cold rolling mill. **Technometrics**, v. 52, n. 1, p. 52–66, 2010.

RAMÍREZ, P. A. P.; UTNE, I. B. Use of dynamic Bayesian networks for life extension assessment of ageing systems. **Reliability Engineering & System Safety**, v. 133, p. 119–136, 2015.

RAUBER, T. W.; VAREJÃO, F. M.; FABRIS, F.; RODRIGUES, A.; RIBEIRO, M. P. Automatic diagnosis of submersible motor pump conditions in offshore oil exploration. **9th Annual Conference of the IEEE Industrial Electronics Society**, Vienna, 2013, p. 5537-5542. Doi: 10.1109/IECON.2013.6700040.

RAUSAND, Marvin. **Risk assessment: theory, methods, and applications**. John Wiley & Sons, 2013.

RAUSAND, M. **Reliability of Safety-Critical Systems: Theory and Applications**. Wiley, Hoboken, NJ. 2014

RAUSAND, Marvin; HOYLAND, A. **Markov processes**. In: **System Reliability Theory**. Wiley, 2008. p. 301-360.

RELATÓRIO DE SEGURANÇA OPERACIONAL. **Relatório de segurança operacional das atividades de exploração e produção de petróleo e gás natural ANP**, 2013.

RELIABILITY ANALYSIS CENTER. The applicability of Markov analysis methods to reliability, maintainability and safety. **START-selected Topic in Assurance Related Technologies**, v. 10, n. 2, 2003.

ROCHA, L. A. S.; AZEVEDO, C. T. de. Projetos de poços de petróleo: geopressões e assentamento de colunas de revestimentos. **Interciência**, Rio de Janeiro, v. 511, 2009.

ROSS, J. V. A stochastic metapopulation model accounting for habitat dynamics. **Journal of Mathematical Biology**, v. 52, p. 788-806, 2006.

SALEM, A. B.; MULLER, A.; WEBER, P. Dynamic Bayesian Networks in system reliability analysis. **Fault detection, supervision and safety of technical processes**, v. 1, p. 444–449, 2007.

SANTOS, M. S.; DAVOLIO, A.; MASCHIO, C.; SCHIOZER, D. J. Estimation of Static and Dynamic Properties in a Bayesian Framework. **European Association of Geoscientists & Engineers**, 2012.

SHARIFFADIN, M. I.; SU, W. **Reliability Assessment of Corroded Pipelines using Bayesian Updating Technique**. 2013.

SHAMSEER, L.; MOHER, D.; CLARKE, M.; GHERSI, D.; LIBERATI, A.; PETTICREW, M.; SHEKELLE, P.; STEWART, L. A. Preferred reporting items for systematic review and meta-analysis protocols (PRISMA-P) 2015: elaboration and explanation. **Bmj**, v. 349, 2015.

SHANKS, E. F.; PFEIFER, W.; SAVAGE, S.; JAIN, A. Enhanced subsea safety critical systems. *In: Offshore Technology Conference, OTC*, 2012.

SICARD, M., Baudrit, C., Leclerc-Perlat, M. N., Wuillemin, P. H., & Perrot, N. (2011). **Expert knowledge integration to model complex food processes**. Application on the camembert cheese ripening process. *Expert Systems with Applications*, 38(9), 11804-11812.

SILVA, V. R. M. da; SAGRILO, L. V. S.; VIGNOLES, M. A. Fatigue reliability assessment for flexible riser armour wires. *In: International Conference on Offshore Mechanics and Arctic Engineering*. American Society of Mechanical Engineers, 2015.

SIMONSEN, A. **Inspection and monitoring techniques for un-bonded flexible risers and pipelines**. Master Thesis. University of Stavanger, Norway (accessed 11.19.22). <https://uis.brage.unit.no/uis-xmlui/handle/11250/219671>.2014.

SIU, N. O.; KELLY, D. L. Bayesian parameter estimation in probabilistic risk assessment. *Reliability Engineering & System Safety*, v. 62, n. 1-2, p. 89-116, 1998.

SINGPURWALLA ND. Foundational issues in reliability and risk analysis. *SIAM Rev* 1988;30(2):264–82.

SKATARIC, M.; BOSE, S.; ZEROUG, S.; TILKE, P. An approach based on Hierarchical Bayesian Graphical Models for measurement interpretation under uncertainty An Approach Based on Hierarchical Bayesian Graphical Models for Measurement Interpretation under Uncertainty. *AIP Conference Proceedings*, v. 140001, 2019. DOI: 10.1063/1.4974716.

SKLET, S. Safety barriers: Definition, classification, and performance. *Journal of loss prevention in the process industries*, v. 19, n. 5, p. 494–506, 2006.

SKOGDALEN, Jon Espen; VINNEM, Jan Erik. Quantitative risk analysis of oil and gas drilling, using Deepwater Horizon as case study. *Reliability Engineering & System Safety*, v. 100, p. 58-66, 2012.

SQUILLANTE JR., R.; FO, D. J. S.; MARUYAMA, N.; JUNQUEIRA, F.; MOSCATO, L. A.; NAKAMOTO, F. Y.; MIYAGI, P. E.; OKAMOTO JR., J. Modeling accident scenarios from databases with missing data: A probabilistic approach for safety-related systems design. *Safety science*, v. 104, p. 119-134, 2018.

STRAUB, D.; DER KIUREGHIAN, A. Bayesian network enhanced with structural reliability methods: methodology. *Journal of engineering mechanics*, v. 136, n. 10, p. 1248–1258, 2010.

SWUSTE, Paul; THEUNISSEN, J.; SCHMITZ, P.; RENIERS, G.; BLOKLAND, P. Process safety indicators, a review of literature. *Journal of Loss Prevention in the Process Industries*, v. 40, p. 162-173, 2016.

SU, A.; FAN, M. The reliability analysis of distribution system based on dynamic bayesian network. *Ciced*, p. 5–6, 2013.

SUBSEA. **Un-bonded flexible risers – recent field experience and actions for increased robustness report** (accessed 11.15.22). 2013. <https://www.ptil.no/contentassets/c2a5bd00e8214411ad5c4966009d6ade/un-bonded-flexible-risers%5frecentfield-experience-and-actions%5ffor-increased-robustness.pdf>.

SUN, F.; LI, H.; CHENG, Y.; LIAO, H. Reliability analysis for a system experiencing

dependent degradation processes and random shocks based on a nonlinear Wiener process model. **Reliability Engineering & System Safety**, v. 215, 2021.

TAYLOR, C.; ØIE, S.; GOULD, K. Lessons Learned from Applying a New HRA Method for the Petroleum Industry. **Reliability Engineering and System Safety**, v. 14, 2020. DOI: 10.1016/j.ress.2018.10.001.2018.

TOLO, Silvia; ANDREWS, John. An integrated modelling framework for complex systems safety analysis. **Quality and Reliability Engineering International**, v. 38, n. 8, p. 4330-4350, 2022.

TORRES-TOLEDANO, J. G.; SUCAR, L. E. Bayesian networks for reliability analysis of complex systems. *In*: COELHO, H. (eds.). **Progress in Artificial Intelligence — IBERAMIA**, 1998. p. 195-206.

WAN, C.; YAN, X.; ZHANG, D.; QU, Z.; YANG, Z. Advanced fuzzy Bayesian-based FMEA approach for assessing maritime supply chain risks. **Transportation Research Part E: Logistics and Transportation Review**, v. 125, p. 222–240, 2019. DOI: 10.1016/j.tre.2019.03.011.

WANG, R.; MA, L.; YAN, C.; MATHEW, J. Condition Deterioration Prediction of Bridge Elements Using Dynamic Bayesian Networks (DBNs). **IEEE**, p. 566–571, 2012.

WANG, S.-F.; ZHANG, Y.-J.; REN, Q.; ZHANG, Y. **An overview of quantitative analysis of distribution system reliability**. **Relay**, v. 36, n. 3, p. 79–83, 2008.

WANG, Y. F.; XIE, M.; NG, K. M.; HABIBULLAH, M. S. **Probability analysis of offshore fire by incorporating human and organizational factor**. **Ocean Engineering**, v. 38, p. 2042–2055, 2011b. DOI: 10.1016/j.oceaneng.2011.09.009.

WANG, Y. F.; XIE, M.; NG, K. M.; MENG, Y. F. **Quantitative risk analysis model of integrating fuzzy fault tree with Bayesian network**. **IEEE**, 2011a. p. 267–271.

WANG, Z.; HUANG, H.-Z.; LI, Y.; PANG, Y.; XIAO, N.-C. **An approach to system reliability analysis with fuzzy random variables**. **Mechanism and Machine Theory**, v. 52, p. 35–46, 2012.

WANG, Wenhe et al. Dynamic failure probability analysis of urban gas pipeline network. **Journal of Loss Prevention in the Process Industries**, v. 72, p. 104552, 2021.

WANG, Mingyuan et al. Hierarchical Bayesian modelling of quasi-region-specific soil porosity. **Ocean Engineering**, v. 266, p. 113052, 2022.

WANG, Y., Liu, S., Chen, Z., Wang, M., Yang, J., & Chen, X. (2021a). **Dynamic Bayesian networks for reliability evaluation of subsea wellhead connector during service life based on Monte Carlo method**. *Journal of Loss Prevention in the Process Industries*, 71, 104487.

WANG, C., Liu, Y., Yu, C., Zheng, Y., & Wang, G. (2021b). **Dynamic risk analysis of offshore natural gas hydrates depressurization production test based on fuzzy CREAM and DBN-GO combined method**. *Journal of Natural Gas Science and Engineering*, 91, 103961.

WANG, C., Xia, Y., Wang, D., Niu, Z., Liu, Y., & Yu, C. (2021c). **Dynamic risk assessment of deep-water dual gradient drilling with SMD system using an uncertain DBN-based comprehensive method.** *Ocean Engineering*, 226, 108701.

WANG, C., Liu, Y., Wang, D., Wang, G., Wang, D., & Yu, C. (2021d). **Reliability evaluation method based on dynamic fault diagnosis results: A case study of a seabed mud lifting system.** *Reliability Engineering & System Safety*, 214, 107763.

WEBER, P.; SIMON, C.; THEILLIOL, D. Reconfiguration of over-actuated consecutive-k-out-of-n: F systems based on Bayesian Network Reliability model. **ACD**, 2010.

WEBER, P.; MEDINA-OLIVA, G.; SIMON, C.; IUNG, B. Overview on Bayesian networks applications for dependability, risk analysis and maintenance areas. **Engineering Applications of Artificial Intelligence**, v. 25, n. 4, p. 671–682, 2012. DOI: 10.1016/j.engappai.2010.06.002.

WILSON, A. G.; FRONCZYK, K. M. Bayesian reliability: Combining information. **Quality Engineering**, v. 29, n. 1, p. 119-129, 2017.

WINBUGS SOFTWARE. **The BUGS project**, 2007. Version 1.4.3.

WU, B.; FENG, Y. Monte-Carlo Bayesian reinforcement learning using a compact factored representation. *In: 4th International Conference on Information Science and Control Engineering (ICISCE)*, 2017. p. 466-469.

WU, S.; ANGELIKOPOULOS, P.; BECK, J. L.; KOUMOUTSAKOS, P. Hierarchical Stochastic Model in Bayesian Inference for Engineering Applications: Theoretical Implications and Efficient Approximation. **ASCE-ASME Journal of Risk and Uncertainty in Engineering Systems**, Part B: Mechanical Engineering, v. 5, n. 1, 2019. DOI: 10.1115/1.4040571.

WU, S.; ZHANG, L.; ZHENG, W.; LIU, Y.; LUNDTEIGEN, M. A. A DBN-based risk assessment model for prediction and diagnosis of offshore drilling incidents. **Journal of Natural Gas Science and Engineering**, v. 34, p. 139–158, 2016. DOI: 10.1016/j.jngse.2016.06.054.

WU, Qingqing; ZHANG, Rui. Intelligent reflecting surface enhanced wireless network: Joint active and passive beamforming design. *In: 2018 IEEE Global Communications Conference (GLOBECOM)*. IEEE, 2018. p. 1-6.

XING, J.; ZENG, Z.; ZIO, E. A framework for dynamic risk assessment with condition monitoring data and inspection data. **Reliability Engineering and System Safety**, v. 191, 2019. Disponível em: <https://doi.org/10.1016/j.ress.2019.106552>. Acesso em:

XU, L.; JIANG, S.; ZHOU, J. The challenges and solutions for deep water drilling in the South China Sea. *In: Offshore Technology Conference, Houston, Texas*, p. 23964, 2013.

YAZDI, M.; KABIR, S. A fuzzy Bayesian network approach for risk analysis in process industries. **Process Safety and Environmental Protection**, v. 111, p. 507-519, 2017.

YANG, X.; UTNE, I. B.; SANDAY, S. S.; RAMOS, M. A.; ROKSETH, B. A systems-theoretic approach to hazard identification of marine systems with dynamic autonomy. **Ocean Eng.**, v. 217, Dec. 2020. Disponível em: <https://doi.org/10.1016/j.oceaneng.2020.107930.2020>. Acesso em:

YILDIZ, B.; BILBAO, J. I.; SPROUL, A. B. A review and analysis of regression and machine learning models on commercial building electricity load forecasting. **Renewable and Sustainable Energy Reviews**, v. 73, p. 1104–1122, 2017.

YONGLI, Z.; LIMIN, H.; LIGUO, Z.; YAN, L. Bayesian network based time-sequence simulation for power system reliability assessment. **IEEE**, p. 271–277, 2008.

YONTAY, Petek; PAN, Rong. A computational Bayesian approach to dependency assessment in system reliability. **Reliability Engineering & System Safety**, v. 152, p. 104-114, 2016.

YU, H.; KHAN, F.; VEITCH, B. A flexible hierarchical Bayesian modeling technique for risk analysis of major accidents. **Risk analysis**, v. 37, n. 9, p. 1668–1682, 2017.

YUNANA, D.; MACLAINE, S.; TNG, K. H.; ZAPPIA, L.; BRADLEY, I.; ROSER, D.; LE-CLECH, P. Developing Bayesian networks in managing the risk of Legionella colonisation of groundwater aeration systems. **Water Research**, v. 193, 2021.

ZAGORECKI, A.; DRUZDZEL, M. J. Knowledge engineering for Bayesian networks: How common are noisy-MAX distributions in practice? **IEEE Transactions on Systems, Man, and Cybernetics: Systems**, v. 43, n. 1, p. 186–195, 2012.

ZAHRA, F. Z.; KHOUAS-OUKID, S.; ASSOUL-SEMMAR, Y. Dynamic bayesian networks in dynamic reliability and proposition of a generic method for dynamic reliability estimation. **Modeling Approaches and Algorithms for Advanced Computer Applications**, p. 409-418, 2013.

ZHANG, Y., Ji, Q., Zhu, Z., & Yi, B. (2008). Dynamic facial expression analysis and synthesis with MPEG-4 facial animation parameters. *IEEE Transactions on circuits and systems for video technology*, 18(10), 1383-1396.

ZAREI, E.; KHAKZAD, N.; COZZANI, V.; RENIERS, G. Safety analysis of process systems using Fuzzy Bayesian Network (FBN). **Journal of Loss Prevention in the Process Industries**, v. 57, p. 7–16, 2019. DOI: 10.1016/j.jlp.2018.10.011.

ZAREI, E.; KHAN, F.; ABBASSI, R. A dynamic human-factor risk model to analyze safety in sociotechnical systems. **Process Safety and Environmental Protection**, v. 164, p. 479-498, 2022.

ZENG, T., Chen, G., Yang, Y., Chen, P., & Reniers, G. (2020). **Developing an advanced dynamic risk analysis method for fire-related domino effects.** *Process Safety and Environmental Protection*, 134, 149-160.

ZENG, L.; GE, Z. Bayesian network for dynamic variable structure learning and transfer modeling of probabilistic soft sensor. **Journal of Process Control**, v. 100, p. 20–29, 2021. DOI: 10.1016/j.jprocont.2021.02.004.

ZHANG, E.; ANTONI, J.; FEISSEL, P. Bayesian force reconstruction with an uncertain model. **Journal of Sound and Vibration**, v. 331, n. 4, p. 798-814, 2012.

ZHANG, H.; JIANG, Y.; JIAO, X.; SONG, X.; HUNG, W. N. N.; GU, M. Reliability analysis of plc systems by bayesian network. **IEEE**, p. 283–290, 2012.

ZHANG, L.; WU, S.; ZHENG, W.; FAN, J. A dynamic and quantitative risk assessment method with uncertainties for offshore managed pressure drilling phases. **Safety Science**, v. 104, p. 39–54, April 2018. DOI: 10.1016/j.ssci.2017.12.033.

ZHANG, L.; WU, X.; SKIBNIEWSKI, M. J.; ZHONG, J.; LU, Y. Bayesian-network-based safety risk analysis in construction projects. **Reliability Engineering & System Safety**, v. 131, p. 29–39, 2014.

ZHANG, X.; ZHANG, L.; HU, J. Real-time risk assessment of a fracturing manifold system used for shale-gas well hydraulic fracturing activity based on a hybrid Bayesian network. **J Nat Gas Sci Eng**, n. 62, p. 79–91, 2019.

ZHAO, X.; GUO, X.; WANG, X. Reliability and maintenance policies for a two-stage shock model with self-healing mechanism. **Reliability Engineering & System Safety**, v. 172, p. 185–194, 2018.

ZHAO, Y.; TONG, J.; ZHANG, L.; WU, G. Diagnosis of operational failures and on-demand failures in nuclear power plants: An approach based on dynamic Bayesian networks. **Annals of Nuclear Energy**, v. 138, 2020. DOI: 10.1016/j.anucene.2019.107181.

ZHENG, H.; PAIVA, A. R.; GURCIULLO, C. S. **Advancing from predictive maintenance to intelligent maintenance with AI and IIoT**, arXiv, 2020.

ZHOU, Z.; JIN, G.; DONG, D.; ZHOU, J.. Reliability analysis of multistate systems based on Bayesian networks. **IEEE**, 2006. p. 6.

ZIO. Some challenges and opportunities in reliability engineering. **IEEE Trans. Rel.**, v. 65, n. 4, p. 1769-1782, Dec. 2016.

## APÊNDICE 1 – Estado da Arte

### 1.A Contextualização

Para identificar a lacuna da literatura focada em análise de risco para esta tese, foi necessário fazer um levantamento bibliográfico nos bancos de dados da *Scopus* e *Web of Science*, para a identificação do estado da arte e da técnica. As publicações foram apresentadas seguindo uma linha cronológica, para facilitar a compreensão da evolução dos estudos e suas aplicações ao longo do tempo. Como mencionado anteriormente, a estrutura de *bowtie* colabora para a investigação de um cenário de acidente, sendo uma técnica robusta para estudo de análise de risco. Sendo assim, algumas palavras-chave foram usadas nesse levantamento, além de se considerar o conhecimento prévio sobre o uso da rede bayesiana e suas vantagens. Com varredura sobre essas técnicas, foi identificada a combinação com outras, em que foi possível verificar na Tabela 28. A consulta empregada nas bases para identificação da lacuna da literatura utilizou o seguinte conjunto de palavras-chaves: *Reliability Analysis*; *Bowtie*; *Bayesian Network*; *Dynamic Bayesian Network*; *Hierarchical Bayesian* e suas combinações.

Observou-se que alguns artigos apresentados eram similares em ambas as bases e, por esse motivo, as duplicatas foram retiradas e apenas contabilizadas uma vez na pesquisa. Os artigos encontrados foram publicados no período de 1963 a 2023. A Tabela 28 apresenta as palavras-chave e suas combinações, com as respectivas quantidades de artigos encontrados.

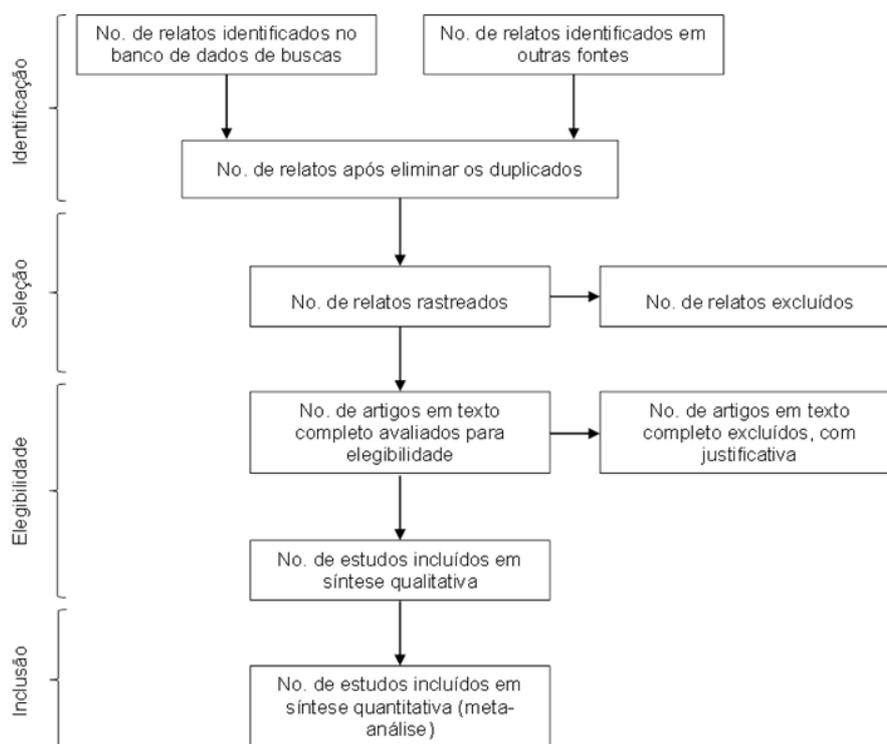
**Tabela 28:** Tabela resumo de artigos para as palavras-chaves das técnicas de análise de risco

Palavras-chaves	Base <i>Scopus</i>	Base <i>Web of Science</i>
<i>Reliability Analysis</i>	79.512	41.129
<i>Dynamic Bayesian Network</i>	3.366	2.856
<i>Hierarchical Bayesian AND Reliability</i>	834	48
<i>Hierarchical Bayesian AND Dynamic Bayesian Network</i>	20	10
<i>Hierarchical Bayesian AND Bayesian Network</i>	1.760	1.020
<i>Bowtie AND Dynamic Bayesian Network</i>	3	1
<i>Bowtie AND Bayesian Network</i>	20	16
<i>Hierarchical Bayesian AND Bowtie</i>	0	0

**Fonte:** O autor (2023)

A Tabela 28 indica que inúmeros artigos foram encontrados com as palavras-chave selecionadas e, por esse motivo, foi necessário realizar uma revisão sistemática da literatura. A metodologia utilizada foi uma adaptação da técnica Prisma (Principais Itens para Relatar Revisões Sistemáticas e Meta-análises), criada por Shamseer et al. (2015), que tem por finalidade identificar os artigos relevantes para o estudo por meio da revisão sistêmica e da meta-análise. A Figura 29 apresenta o fluxograma com as fases de execução dessa técnica

**Figura 26:** Fluxo de informação do método PRISMA



**Fonte:** Shamseer *et al.*, (2015)

De acordo com o fluxograma, existem quatro critérios que compõem a análise da revisão, são eles: identificação, seleção, elegibilidade e inclusão. Abaixo, cada um deles será abordado com detalhes.

### 1. Identificação

Na fase de identificação, é feita uma varredura de trabalhos que auxiliam na elaboração da pesquisa. Esta pesquisa fez uma coleta de artigos até junho de 2023, através das bases bibliográficas com as palavras-chave mencionadas anteriormente. A coleta também foi feita em teses e dissertações, em catálogos de

Universidades como Unicamp, USP, UFRJ, UFBA, entre outras. A figura a seguir apresenta o resumo dessas informações.

## **2. Seleção**

Na fase de seleção, é feita a leitura dos títulos e resumos dos artigos encontrados nas bases. Essa primeira triagem verifica a importância de cada pesquisa e sua relação com a temática. Nessa segunda etapa, os artigos selecionados foram divididos de acordo com o ano de publicação e o número de citações. Utilizando essa abordagem, foi possível excluir artigos considerados não relevantes. Além disso, certos artigos encontrados não estavam disponíveis para acesso e, por isso, foram excluídos da análise.

## **3. Elegibilidade**

Na fase de elegibilidade, é feita a leitura completa dos artigos, dos trabalhos de dissertação e tese selecionados como relevantes. Nessa etapa, artigos foram descartados por não oferecerem embasamento previsto para a revisão da literatura e não apresentavam as informações de interesse da pesquisadora.

## **4. Inclusão**

Após a elegibilidade, foram incluídas pesquisas que colaboraram para a construção da revisão da literatura e da fundamentação teórica. As publicações utilizadas foram agrupadas de acordo com os temas abordados para facilitar a escrita de acordo com a informação oferecida.

### **1.B Revisão Bibliográfica da Rede Bayesiana Dinâmica**

A sequência lógica de apresentação desta seção foi construída baseada no avanço temporal do estudo da confiabilidade, de acordo com as pesquisas realizadas. As primeiras contribuições metodológicas e de aplicações de rede bayesiana foram feitas pelas pesquisas de Cole, (1975), Pearl (1988), Jensen (1996) e Neil, Littlewood e Fenton (1996). Inicialmente, os estudos estavam atrelados a solucionar problemas de um sistema específico, a partir da criação de redes construídas pelos conhecimentos de especialistas sobre o objeto de interesse. Alguns exemplos foram: o trabalho de Mahadevan, Zhang e Smith (2001), em estruturas mecânicas e civis; os de Gran e Helminen (2001) e Celeux, Corset e Lannoy (2006), com o estudo em usinas nucleares; o de Yongli *et al.* (2008), em sistemas de energia; e em *offshore* com o trabalho de Droguett *et al.* (2006).

Para criação de uma rede bayesiana, as informações sobre os nós, a associação e a probabilidade entre eles devem ser conhecidas *a priori*. Para a criação desse modelo, o especialista deve ter conhecimento significativo sobre o sistema empregado. O trabalho de Bouissou, Martin e Ourghanlian (1999) teve como proposta apresentar um método de construção de rede bayesiana de hierarquia *top-down*, combinando evidências de diferentes fontes no cálculo da confiabilidade em sistemas de segurança críticos.

O estudo da rede bayesiana foi evoluindo com o passar dos anos devido aos avanços tecnológicos nos sistemas, tornando-os mais complexos e gerando, assim, ambiente mais propício para o desenvolvimento desse método, vistos os benefícios de seu uso: a consideração de dependências funcionais entre os componentes, o comportamento temporal dos sistemas, os múltiplos estados de falha dos componentes e a incerteza no comportamento do sistema e os dados de falha (KABIR; PAPADOPOULOS, 2019). Com o desenvolvimento desse método, vários estudos foram sendo aplicados. Nas pesquisas de Jiang *et al.* (2012) e Zhang *et al.* (2012), foi criado e empregado um método híbrido de análise de confiabilidade, utilizando rede bayesiana para sistemas de programação lógica de controle (PLC), que consideram complexas dependências entre os componentes. Outro método híbrido foi desenvolvido por Neil e Marquez (2012), ao modelarem a disponibilidade de sistemas reparáveis em rede bayesiana. No trabalho de Marquez, Neil e Fenton (2010), é apresentada uma combinação de variáveis discreta e contínua no cálculo da confiabilidade, usando rede bayesiana. Nos trabalhos de Weber *et al.* (2012) e Hänninen (2014), são apresentadas, por meio de uma revisão bibliográfica sobre rede bayesiana, suas aplicações na análise de risco e em áreas de manutenção, além de apresentarem os benefícios e desafios de aplicação dessa técnica em segurança marítima e análise de acidentes, respectivamente.

O uso de *software* foi uma alternativa incluída na aplicação de rede bayesiana para casos de inferência das probabilidades. O trabalho de Kelly e Smith (2009) utilizou a simulação de Monte Carlo para o cálculo das distribuições conjuntas das variáveis selecionadas. Entretanto, com as limitações de tempo de execução e os requisitos de memória, algumas alternativas foram sendo criadas. O estudo de Cadini e Gioletta (2016), por exemplo, propôs um novo método, conhecido como Monte Carlo Bayesiano, para estimar pequenas probabilidades. Entretanto, outros autores seguiram novos caminhos, distanciados da computação, como Guan *et al.* (2012), que propuseram uma abordagem analítica para estimativa da confiabilidade, criando e usando o método de Laplace combinado com rede bayesiana.

A estimativa da confiabilidade na maioria dos sistemas é gerada pela base de dados precisos sobre a vida útil dos componentes. No entanto, nem sempre essas informações estão disponíveis. A rede bayesiana é capaz de lidar com incertezas aleatórias ou intencionais no seu cálculo de estimativa. Uma das incertezas pode estar presente no método de definição da probabilidade, como o uso da lógica *fuzzy*. No trabalho de Yazdi e Kabir (2017), utilizou-se, em conjunto com essa técnica, a opinião de especialista para lidar com a incerteza nos dados de falha, empregando a modelagem de rede bayesiana para realizar a dependência entre os eventos e sua relação probabilística. Zhang *et al.* (2014) propuseram o uso da teoria *fuzzy* combinada com a rede bayesiana para análises de risco de segurança em projetos de construção de túneis, com a finalidade de investigar as relações causais entre os danos e suas variáveis influentes nesse tipo de estrutura. E em Zarei *et al.* (2019), a utilização de uma nova metodologia híbrida, conhecida como rede bayesiana *fuzzy* (FBN), teve como objetivo determinar as probabilidades, aplicando o mesmo raciocínio da lógica *fuzzy*, ao utilizar algoritmo de inferência de rede bayesiana convencional para análise preditiva e atualizando as probabilidades usando a elicitación de especialistas. Outro método a ser utilizado para cálculo de incerteza, em caso de escassez de dados, é o uso da modelagem pelo método de hierárquica bayesiana. Os estudos de Yu, Khan e Veitch (2017) e Wu *et al.* (2019) desenvolveram esse técnica junto à rede bayesiana e à árvore de evento, a fim de encontrarem a probabilidade de falha de um sistema nessas condições.

Um aspecto considerado em estudos de sistemas de confiabilidade é a análise de confiabilidade humana. Suas características estão em identificar sistematicamente e analisar as causas e efeitos provocados por erros humanos em sistemas operacionais. Em sua pesquisa, os autores Mkrtyan, Podofillini e Dang (2015) propuseram a construção das tabelas de probabilidade condicionais da rede bayesiana, considerando a análise de confiabilidade humana devido à escassez de dados. Assim como o estudo de Podofillini e Dang (2013), que determinou a relação entre o desempenho condicional e essa probabilidade de erro, ao agregar o julgamento de especialista na probabilidade de erro humano. Além dos estudos de Cai *et al.* (2013b), Baraldi *et al.* (2015) e Musharraf *et al.* (2016), em que os cálculos de confiabilidade em rede são contabilizados considerando o fator humano como influenciador da probabilidade de falha do sistema em operações *offshore*, como em perfuração, e no estudo de evento *blowout*.

Ao mesmo tempo em que a abordagem com fatores humanos foi sendo desenvolvida, a rede bayesiana também foi sendo aplicada/convertida em outros modelos de análise de risco. A pesquisa de Torres-Toledano e Sucar (1998) trouxe a modelagem do sistema de confiabilidade usando diagrama de bloco para rede bayesiana. A partir desse conhecimento, os autores iniciaram a conversão dessa estrutura em blocos para uma rede bayesiana, como nas pesquisas de Kim (2011) e Zhou *et al.* (2006), em que foram considerados estados binários e múltiplos estados dos componentes, respectivamente, nessa conversão. Prosseguindo a evolução, a utilização da falha de causa comum, apresentada no estudo de Mi *et al.* (2012), realizando, assim, o cálculo da confiabilidade do sistema em meio a essa condição.

Outro modelo utilizado para conversão em rede bayesiana (RB) foi a árvore de falha (AF). O pioneiro nessa transformação foi o trabalho de Bobbio *et al.* (2001), depois, diversos setores aplicaram essa conversão ao longo dos anos, como apontado nos trabalhos de Khakzad, Khan e Amyotte (2011), Lampis e Andrews (2009), Mahboob e Straub (2012). Além disso, houve integrações da AF com RB seguindo uma análise de confiabilidade humana, como apresentado no trabalho de Martins e Maturana (2013), em tanques de óleo. Essa análise foi tomando proporções maiores, quando foi considerada a dinamicidade das operações, cuja árvore de falha dinâmica foi combinada com a rede bayesiana dinâmica, como apresentado em Barua *et al.* (2016), ou combinando com a lógica *fuzzy*, em Wang *et al.* (2011a).

As técnicas de análise de risco, como FMEA, *bowtie*, rede de Petri e árvore de evento, também são combinadas com a rede bayesiana para resolver problemas em sistemas complexos. Como exemplos, estão a pesquisa de Wang *et al.* (2011), no uso do FMEA e o método de rede bayesiana isomórfico, e em Wan *et al.* (2019), com o estudo de risco de cadeia de suprimentos marítima, usando lógica *fuzzy*, rede bayesiana e FMEA. Na análise de *bowtie*, os trabalhos de Abimbola *et al.* (2015) e Khakzad *et al.* (2013a) estudaram os riscos e a segurança em processos de perfuração de poços e no conselho de segurança química dos EUA, em uma análise de segurança dinâmica, respectivamente. A rede de Petri é incorporada à rede bayesiana no trabalho de Andrews e Fecarotii (2017), que investigaram o efeito dos recursos de manutenção e de *design* no desempenho do sistema em plataformas de óleo e gás. E, finalizando, para a árvore de evento, os trabalhos como os de Bearfield and Marsh (2005), Li, Tao e Jia (2015) investigaram a modelagem de segurança para o caso de descarrilamento de trem,

combinando a rede bayesiana com a árvore de evento, realizando a análise de risco de árvore de falha e rede bayesiana.

A complexidade dos sistemas operacionais, a realização de manutenções, a necessidade de dinâmica dos processos e o estudo de aplicação da cadeia de Markov foram fatores que promoveram a evolução da aplicação de uma rede bayesiana estática para dinâmica. Como exemplo, o trabalho de Cai *et al.* (2015) propôs combinar a rede bayesiana clássica e a dinâmica, ao longo do tempo, para comparar as diferenças das probabilidades de falhas de causa raiz encontradas em tubulações de sistemas de segurança em poços de petróleo e, assim, determinar melhor as ações preditivas de manutenção. E Fan *et al.* (2019) incorporaram a árvore de evento dinâmica, baseada em rede bayesiana dinâmica, com finalidade de modelar uma estrutura de cálculo de probabilidade de falha para eventos que degradam ao longo do tempo.

A rede bayesiana dinâmica também foi combinada com outras técnicas de análise de risco, como: a árvore de falha estática e dinâmica, no setor de óleo e gás, em Cai *et al.* (2013a); Khakzad, Khan e Amyotte (2013), Li *et al.* (2019) e Pang, Yu and Song. (2021); a árvore de evento estática, no estudo de Li, Tao e Jia (2015), e dinâmica, com cadeia de Markov, no artigo de Fan *et al.* (2019); a modelagem bayesiana hierárquica, como em Li *et al.* (2019); com Monte Carlo, como em Wu e Feng (2017) e Li *et al.* (2018); e o método de *fuzzy* para acidentes de explosão, como em Ji *et al.* (2018), em reator nuclear, no estudo de Gui *et al.* (2022), e em *gas pipeline*, em Bingyuan Hong *et al.* (2023). Todas essas pesquisas criaram uma modelagem de análise de risco considerando condições diversas para cada cenário analisado.

Uma alternativa estudada encontrada foi a conversão da árvore de falha em rede bayesiana dinâmica, utilizada por pesquisadores como Cai *et al.* (2013a), criando um novo modelo que considera reparos imperfeitos e ações de manutenção em sistemas *offshore*, no estudo em navios de superfícies não tripulados, apresentado por Gao *et al.* (2021), para sistemas de *Flare*, como abordado por Kabir *et al.* (2023), entre outros.

Assim como aconteceu na rede bayesiana estática, o método dinâmico também foi modelado considerando as condições operacionais contidas em cada sistema específico. A aplicação da rede bayesiana com falha de causa comum em *subsea* foi realizada nos estudos de Liu *et al.* (2015b) e Li *et al.* (2020). A aplicação de fatores humanos como influenciadores na probabilidade de falha é modelada pelas pesquisas de Cai *et al.* (2013b) e Zarei, Khan e Abbassi (2022), incluindo esses fatores nas tabelas de probabilidade condicional e criando uma modelagem. O estudo de Cai *et al.* (2013c)

aplicou a rede bayesiana dinâmica para o cálculo de confiabilidade do sistema de controle do BOP (*Blowout Preventer*), considerando reparos imperfeitos, múltiplos estados de degradação e manutenção preventiva. O cenário com múltiplas falhas e falha por demanda foi representado na pesquisa de Zhao *et al.* (2020), em plantas nucleares; e em caso de consideração de fadiga, o estudo de Heng *et al.* (2019), em *decks* de aço. O estudo realizado por Ramírez e Utne (2015) aplicou a rede bayesiana dinâmica para avaliar a extensão de vida de sistemas reparáveis antigos, a fim de fornecer suporte à decisão, com base no desempenho do sistema durante um horizonte de tempo finito, para estender o período de vida útil. E para casos de estudos considerando incerteza de dados e variação de informações, temos Jia *et al.* (2019), Li *et al.* (2022), Meng *et al.* (2022), que enfatizaram suas análises em sistemas complexos.

Esse método dinâmico foi evoluindo e se aperfeiçoando ao longo dos anos, como apresentado pelo estudo de Cai, Liu e Fan (2016), que propôs uma nova metodologia com rede bayesiana dinâmica multifásica na determinação do nível de integridade de segurança (SIL) de um poço; e por Zahra, Khouas-Oukid e Assoul-Semmar (2013), que criaram um método genérico para cálculo de confiabilidade por meio da rede bayesiana dinâmica.

Pode-se dizer que a rede bayesiana dinâmica sofreu uma evolução, ao considerar diferentes condições de cenários a serem estudados, como o uso de incerteza, condições de operação, como múltiplos estados de falha, falha de causa comum, reparo perfeito e imperfeito, taxa de falha discreta ou contínua, múltiplas fontes de coleta de dados para o cálculo da confiabilidade, fadiga, fatores humanos em várias áreas, com a finalidade de contribuir para a identificação e cálculo do risco e, assim, para a tomada de decisões operacionais de manutenção.

## APÊNDICE 2 – Estado da Técnica

Após realizar a varredura bibliográfica, foram identificadas as organizações e indústrias que aplicaram a rede bayesiana dinâmica em seus sistemas/operações. As áreas encontradas compreendem as de óleo e gás, química, alimentícia, biológica, vídeo e imagem, e ciência da computação e matemática. A subseção a seguir contém a descrição das aplicações desse método nessas indústrias. Para a área de óleo e gás, as pesquisas foram realizadas pelas seguintes organizações: Shell, Petrobrás, *Exxonmobil*, *Schlumberger*, CRISE (*Centre for Risk, Integrity and Safety Engineering*), *Research Institute of China National Offshore Oil Corporation*, CNOOC (*China National Offshore Oil Corporation*), *Oil Production Service Co.*, CNPC (*China National Petroleum Corporation*). Na indústria de vídeo e imagem, as empresas *Magic Pixel* e *Sarnoff Corporation* possuem estudos associados; na biológica, foi a empresa INSERM (*Institut National de la Santé et de la Recherche Médicale*); para a área de Ciência da Computação e Matemática, foram as organizações INRIA-Saclay, CSIR (*Council for Scientific and Industrial Research*) e Siemens AG; na indústria química, a CEDON (*Center for Economics and Corporate Sustainability*), e na indústria alimentícia a empresa *Génie et Microbiologie des Procédés Alimentaires*. Essas pesquisas demonstram como diversas empresas investiram em análise de confiabilidade para controlar os riscos e desenvolver suas áreas de aplicação.

### A.2.1 Empresas da área de Óleo e Gás

#### A.2.1.1 Empresa Shell

As atividades *offshore* são consideradas de alto de risco, pois são operações de alta complexidade e podem provocar consequências de elevada severidade mediante certas falhas. Por isso, as empresas desse setor veem valor em analisar o risco, avaliar as possíveis falhas e promover ações para minimizar as probabilidades de ocorrência. A pesquisa realizada por Babaleye, Khorasanchi e Kurt (2018) descreveu um problema enfrentado pelas empresas no setor de óleo e gás, devido a sua natureza arriscada, complexa e custosa, conhecida como descomissionamento de estruturas Jacket. Nesse estudo foi realizada uma modelagem quantitativa de risco com rede bayesiana para atualização das probabilidades de falha dos elementos de causa do descomissionamento. Para essa pesquisa foram utilizados dados reais da plataforma Brent Alpha, da Shell,

com a finalidade de identificar os riscos e os elementos mais críticos da operação que precisam ser gerenciados para prevenir catástrofes.

Outro evento em questão considerado de alto risco para as empresas do setor de óleo e gás é o transporte de hidrocarboneto por meio de tubos. Esses tubos estão sujeitos a deterioração ao longo do tempo, devido à corrosão interna e externa, que pode gerar alto risco, caso não haja ações para mitigá-la. Por isso, são usadas ferramentas de inspeção para verificação do estado dos tubos. Há uma preocupação por parte das organizações sobre o tempo de reparo, pois, ao superestimar esse valor, os reparos são mais frequentes, levando a possíveis inspeções desnecessárias, além de causar danos ao componente. Devido à criticidade desse cenário e para evitar erros de estimação, o estudo de Shariffadin e Su (2013) utilizou rede bayesiana para atualizar as probabilidades de falha e de sobrevivência do componente e ajudar na estimativa da ocorrência das inspeções.

Um cenário existente em algumas plataformas, inclusive da empresa Shell, é o ataque de piratas nas unidades por todo o globo. Essas invasões causam mortes, danos aos equipamentos, explosões e altos custos de manutenção. Para reduzir a vulnerabilidade, as operadoras tiveram a iniciativa de investigar as tecnologias de informação e comunicação para estimar esse cenário. A pesquisa de Chaze e Napoli (2013) descreveu um protótipo em rede bayesiana utilizando técnica de inteligência artificial para avaliar os riscos de ataque contra plataformas.

#### **A.2.1.2 Empresa Petrobrás**

A disponibilidade de equipamentos e dos sistemas em funcionamento são atributos chaves para a eficiência das atividades *offshore*, pois maior disponibilidade significa maiores volumes de produção. Entretanto, a avaliação dessa disponibilidade possui uma complexidade cujos aspectos mais relevantes são: o tempo disponível para concluir a manutenção; o sistema estar em processo de deterioração; e a probabilidade de erro humano durante a manutenção, que engloba a experiência e a fadiga, para que retornem à condição operacional normal. A pesquisa de Droguett *et al.* (2008) combinou o modelo de rede bayesiana com processo semi-markoviano de tempo contínuo para caracterizar as relações causa e efeito dos fatores influenciadores na probabilidade das atividades operacionais. Para aplicação desse caso, foram utilizados dados reais de poços de petróleo da Petrobrás.

Outro cenário de alto risco é a probabilidade de incêndio em plataformas. A pesquisa de Wang *et al.* (2011b) incorporou o efeito do erro humano e os fatores organizacionais no cálculo da probabilidade desse cenário, utilizando a combinação do método de árvore de falha e de rede bayesiana. Portanto, os possíveis cenários de incêndio são modelados a fim de criar uma cadeia causal e realizar uma análise quantitativa por meio de um algoritmo de integração.

Com o investimento em águas profundas, um problema existente na unidade produtora é a detecção e diagnóstico de falha das bombas elétricas de submersão. A pesquisa de Rauber *et al.* (2013) utilizou rede bayesiana e avaliação estatística na realização de experimentos para identificar as condições de desempenho das bombas com a opinião de especialistas.

O estudo de Droguett *et al.* (2008) combinou rede bayesiana dinâmica com modelo de Markov para avaliar a disponibilidade de sistemas de monitoramento óptico no fundo do mar. E Santos *et al.* (2012) utilizaram o modelo bayesiano para estimar a saturação do fluxo e a porosidade com a variação de pressão na água nos diferentes cenários de produção.

Os reservatórios de pré-sal brasileiros são altamente heterógenos devido à natureza do sistema deposicional e dos processos digenéticos. Por esse motivo, a estimativa de reserva e a previsão de produção estão sujeitas à incerteza. Para esse cenário, o estudo de De Mello e Lupinacci (2022) aplicou a abordagem bayesiana para obter a descrição detalhada sobre a disposição espacial das rochas aplicada do Campo de Búzios e colaborar na estimativa de produção desse poço.

### **A.2.1.3 Empresa Exxonmobil**

A exploração em bacias onde a distribuição geográfica e a qualidade do reservatório não estão bem especificadas e documentadas, devido serem remotas ou de difícil processo de perfuração e visualização, é um exemplo de risco. Por esse motivo, é feita uma análise completa do sedimento, como a sua geração (local, de que tipo, em que condições ambientais), transporte (gradientes topográficos, mecanismos de transporte) e deposição (batimetria da bacia e mecanismos de deposição) para delinear a distribuição e o caráter mais provável dos sedimentos na bacia. Para isso, a Exxonmobil utiliza extensos bancos de dados globais, *software* patentado e fluxos de trabalho para garantir as informações genéticas necessárias e, assim, incorporá-las durante a exploração para orientação e interpretação dos riscos do reservatório. Um exemplo está apresentado no

trabalho de Heins, O'Grady e Ardiç (2008), aplicado em rede bayesiana, a fim de ajudar na análise dos riscos de exploração dessas bacias, de acordo com as características genéticas dos sedimentos.

O gerenciamento de segurança de processo (PSM) é um sistema robusto de gestão que envolve a análise de risco associado ao todo o ciclo de vida de um procedimento comumente utilizado em segurança de processo na indústria de óleo e gás. O número de riscos de segurança sofre variações durante a vida do processo, devido a fatores como: o desempenho das barreiras de segurança, as condições dos equipamentos, o histórico dos incidentes e a competência dos funcionários. Para os cenários de risco, existem inúmeras técnicas de análise quantitativas e qualitativas de risco para gerenciar os principais perigos. Entretanto, a natureza dinâmica dessa avaliação do risco é valiosa, com o fim de facilitar a visualização de suas mudanças probabilísticas para melhor realizar o embasamento na tomada de decisão. Por isso, o setor de óleo e gás tem avançado os seus esforços para o desenvolvimento de indicadores de desempenho de segurança (KPIs) para mensurar a eficiência dos sistemas de gestão de segurança e, assim, reduzir o risco dos principais incidentes em tempo real com fontes variadas de informação. Visto isso, a Exxonmobil, em parceria com *Mary Kay O'Connor Process Safety Center*, desenvolveu uma metodologia que oferece uma ferramenta para monitorar em tempo real o potencial de aumento do nível de risco usando KPIs como evidências e se apoiando no método da rede bayesiana para sua estruturação dinâmica (KANES et al., 2017).

O gerenciamento de reservatório é o conjunto de técnicas que permite extrair o máximo de volume possível de petróleo dentro dos reservatórios e ganha complexidade no ambiente de águas profundas e ultra profundas. Por essa dificuldade, é necessário definir as recomendações sobre a eficiência e a qualidade de diferentes métodos para aplicações na previsão da produção, dando apoio ao processo de tomada de decisão em gestão de reservatórios. O estudo de Araújo *et al.* (2019) comparou cinco métodos para identificar essas recomendações e dar apoio aos planejamentos de ações.

Outra questão levantada pelos pesquisadores da empresa Exxonmobil é a manutenção preditiva contemplada no trabalho de Zheng, Paiva e Gurciullo (2020). A partir do uso da inteligência artificial, os autores abordam o estudo da modelagem de confiabilidade, considerando manutenção inteligente com algoritmos de aprendizado de máquinas recentes e modelagem probabilística; coleta e armazenamento de dados em tempo real por meio de sensores inteligentes sem fio, tecnologia de *big data* e

integração; e implantação contínua de modelos de aprendizado de máquinas. Esse processo é aplicado a um motor de Turbofan com dados de degradação. Para isso, foi aplicada uma rede neural bayesiana para modelar a distribuição contínua e dinâmica não linear entre as variáveis propostas para as configurações da máquina e medição do sensor.

#### **A.2.1.4 Empresa Schlumberger**

Um estudo realizado pela empresa Schlumberger sobre resistividade foi desenvolvido considerando o abalo sísmico ocorrido em Koyna, que impactou o seu reservatório. A compreensão da distribuição padrão da resistividade em área sísmica crítica é importante para mapear falhas e fraturas. Visto isso, o estudo de Maiti *et al.* (2011) aplicou rede neural bayesiana com abordagem híbrida de Monte Carlo para interpretação de dados de resistividade. Esse método permite estimar medidas de incerteza, apropriado para o universo geofísico.

O estudo de Achumba *et al.* (2012) identificou três técnicas de construção: a centralizada totalmente no especialista, a centralizada nos dados e as semicentradas nos dados, a fim de investigar empiricamente qual dessas abordagens é ideal para a construção de um modelo de rede bayesiana. Essa pesquisa teve suporte da empresa Schlumberger para aplicação em seus sistemas críticos.

Os sistemas de automação do processo de construção do poço possuem um rastreamento de estado operacional dos equipamentos, dos processos e do poço para manter as operações seguras e eficientes. Os algoritmos robustos de detecção dos estados dependem de modelos incertos e de dados de sensores imperfeitos. A solução proposta no estudo de Chambon *et al.* (2018) implementou uma modelagem combinando inferência e rede bayesiana, a partir do fluxo de dados dos sensores de entrada, a fim de classificar as observações com o estado das operações, como exemplo, a perfuração com os dados referentes à rotação de fundo.

Uma das operações realizadas pelas empresas do setor de óleo e gás é o processo de cimentação, em que é colocado cimento entre o espaço anular entre o revestimento e a formação rochosa. A alta qualidade de execução desse processo fortalece o isolamento da área resultante da presença de uma bainha de cimento que se liga ao revestimento, protegendo-o da corrosão causada pelo fluido de formação. Esse isolamento evita o fluxo intersazonal descontrolado de fluidos, que leva a consequências ambientais e erosão da formação (NELSON; GUILLOT; CEMENTING, 2006). A perfilagem acústica

é utilizada como ferramenta para avaliar a qualidade do processo de cimentação. Essa técnica utiliza as propriedades acústicas do fluido de poço, revestimento e cimento. O resultado gerado fornece a interpretação sobre a alta resolução do material atrás do revestimento. Devido à riqueza dos dados, há desafios que surgem com a presença de ambiguidades e inconsistências, devido a fatores incertos nas propriedades do dispositivo de medição, dados de medição ou erro humano. Algumas dessas incertezas não podem ser descritas por quaisquer modelos matemáticos. Por isso, o trabalho de Skataric *et al.* (2019) utilizou uma modelagem hierárquica bayesiana de gráfico para interpretar os problemas multidimensionais e complexos, considerando as incertezas paramétricas dos elementos físicos. Na análise bayesiana, todos os parâmetros são tratados como variáveis aleatórias e a inferência dos parâmetros é baseada na distribuição *posteriori* calculada pelas evidências observadas.

#### **A.2.1.5 CNOOC**

O conector da cabeça do poço é um elemento considerado crítico para o processo de perfuração e produção de óleo e gás devido ser um local de possível vazamento de combustíveis fósseis devido ao excesso de sobrecarga gerada pelas forças da natureza e outras forças de suporte que atuam nesse elemento. A pesquisa de Wang *et. al* (2021a) realizou uma análise de confiabilidade sobre esse equipamento apoiado na metodologia de rede bayesiana dinâmica combinada com o método de simulação de Monte Carlo com o objetivo de identificar a probabilidade de falha do conector ao longo do tempo. Nesse estudo, a análise quantitativa estava sujeita à uma margem de erro devido os fatores influenciadores desse equipamento possuem incerteza visto à entrada de dados pelo método de Monte Carlo. Essa simulação colabora na tomada de decisão da engenharia sobre as prováveis medidas de intervenção e preventivas para a possível falha do conector da cabeça do poço no setor offshore, como exemplo, para evitar o deslocamento vertical e fortalecer as propriedades do material usado no anel de acionamento.

#### **A.2.1.6 *Research Institute of China National Offshore Oil Corporation***

A cabeça do poço é um componente relevante para o processo de perfuração de poço no setor de óleo e gás devido a sua falha possivelmente causar a perda de integridade do poço e à acidentes catastróficos que são impactantes para a economia da

empresa, o meio ambiente e para os funcionários envolvidos. A pesquisa de Chang *et. al* (2019) realizou um estudo de análise de risco desse equipamento baseado em rede bayesiana dinâmica e inferência bayesiana a fim de prever a probabilidade de falha por fadiga dele. A estimativa quantitativa de risco está sujeita a uma margem de erro obtida pela utilização do julgamento de especialistas e a teoria fuzzy para as taxas de falha dos componentes associados a esse equipamento. Portanto, essas informações obtidas nesse estudo foram úteis para as tomadas de decisão em medidas preventivas e de intervenção para esse tipo de falha.

#### **A.2.1.7 Oil Production Service Co**

A formação de hidratos de gás natural é um fator preponderante para o sucesso da exploração offshore, pois ele dificulta o escoamento do petróleo, implicando na perda de produtividade e gera danos à equipamentos. O estudo Wang *et. al* (2021b) apresentou a combinação do método GO (uma análise de confiabilidade usada para análise de segurança de multiestados e sistemas sequenciais) e a rede bayesiana dinâmica para estudar o processo de teste de produção de despressurização de hidrato de gás natural. Foi considerado a interferência do fator humano na modelagem usando o método de peso usando na técnica de fuzzy CREAM (Método de análise de erro). Foi avaliado o desempenho do equipamento, o risco operacional e a probabilidade de formação secundária de hidrato durante o processo de produção. O modelo de rede bayesiana dinâmica foi verificado e validado por uma rede de Petri. Foi concluído pelo estudo, que a degradação do equipamento e o fator humano preponderante e influenciadores negativos para a formação desse hidrato secundário.

Outro estudo realizado nessa área, foi a pesquisa no sistema de levantamento de lama (*subsea mudlift drilling system*) durante a perfuração realizado por Wang *et. al* (2021b) para a formação de hidrato de gás natural. A fim de prever a falha do sistema, é considerado o fator humano, do meio ambiente e a degradação dos equipamentos. Nesse estudo foi construído inicialmente uma árvore de falha que foi transformada em uma rede bayesiana dinâmica com incerteza por meio da inclusão do nó *Leaky Noisy-OR*. Somado a isso, foram adicionadas a confiabilidade cognitiva e o método de análise de erro (CREAM) usado para determinar a probabilidade a priori dos fatores humanos na rede bayesiana dinâmica. Para a falha dos equipamentos, é utilizado a opinião de especialistas e a lógica fuzzy. Esse estudo constatou que esse modelo criado é capaz de

prever o risco de perda de circulação, aderência e bloqueio durante o processo de perfuração, além de determinar a probabilidade de sucesso em diferentes estágios do processo de fechamento do sistema de lama.

Como aperfeiçoamento do estudo anterior, Wang *et. al* (2021d) propôs um método de avaliação da confiabilidade baseado em resultados de diagnóstico dinâmico de falha. O exemplo é validado pela aplicação no sistema de elevação de lama do fundo do mar. Esse método leva em consideração a degradação dos sensores e dos equipamentos. É adicionado a pesquisa a influência da causa comum, a degradação multiestados dos elementos e a degradação de performance dos sensores. Foi percebido que com a inclusão da causa de falha comum, a confiabilidade é ligeiramente inferior quando não considerada no sistema. E, para o caso de confiabilidade do sistema considerando múltiplos estados de degradação, ela é ligeiramente maior quando não considerada. Sendo assim, a degradação influencia mais na confiabilidade do sistema de elevação de lama do que a causa de falha comum.

#### **A.2.1.8 CRISE**

A pesquisa de Mamudu *et. al* (2020) apresentou um modelo híbrido para prever a produção de petróleo e fornecer um perfil de risco dinâmico do sistema de produção. O modelo associa o modelo de redes neurais (RNA) com percepção de múltiplas camadas (MLP) e a rede bayesiana dinâmica. A metodologia proposta, chamada de MPL-BN-DBN, teve a finalidade de encontrar as correlações entre os dados de entrada e saída para prever a taxa de produção do petróleo desejada. O MPL tem a finalidade de capturar as variabilidades nas propriedades dos fluidos e das rochas, as incertezas e o efeito da manutenção de pressão no processo produtivo. A rede bayesiana sinaliza qualquer mudança de taxa de produção. E a rede bayesiana dinâmica fornece um perfil de risco dinâmico do sistema de produção usando as evidências observadas e conceito de declínio hiperbólico da produção dos reservatórios. Essa proposta metodológica tem o objetivo de oferecer uma melhor estimativa em tempo real da probabilidade de qualquer perda iminente de produção a qualquer momento durante as operações de produção.

### **A.2.1.9 CNPC**

Em um ambiente dinâmico, os sistemas estruturais sofrem degradação devido a múltiplos fatores causados que estão sujeitos a alta incerteza. A pesquisa de Cai *et. al* (2019) propôs um método híbrido baseado em modelos físicos e combinada com a metodologia de estimativa de vida útil (RUL) considerando múltiplas causas representadas pelo modelo de rede bayesiana dinâmica. A insuficiência de dados é solucionada pelo uso de modelos físicos teóricos ou empíricos para a estruturação e modelagem dos parâmetros da rede bayesiana dinâmica para o processo de degradação. O modelo RUL é obtido pela diferença de tempo entre a detecção e o previsto pela falha, que é determinado pelo limite de falha de desempenho. O julgamento de especialistas e os dados dos sensores são inseridos no modelo de estimativa do RUL. A aplicação é feita para o sistema de dutos do sistema offshore de produção de petróleo e gás. Para isso, foi considerada a degradação como corrosão, fadiga, erosão arenosa e ondas internas que foram modeladas pela rede bayesiana dinâmica. Foi percebido que a profundidade da fissura foi sensível à diferentes velocidades e, posteriormente, a faixa de tensão das ondas internas. Portanto, a profundidade inicial da fissura deve ser detectada e controlada rigorosamente durante a instalação. E, o ciclo de revisão deve ser encurtado quando as ondas internas fortes ocorrem com frequência.

Outro estudo realizado associou os métodos de avaliação de resiliência de sistema de engenharia que possuem uma limitação com relação aos desastres externos fixos considerados no cálculo. O estudo de Cai *et. al* (2021) combinou a rede bayesiana dinâmica e o modelo de Markov para desenvolver uma metodologia que fosse capaz de avaliar a influência de vários desastres externos variados. O exemplo utilizado como base para apresentação dessa metodologia foram os sistemas de fornecimento de energia e controle de preventores submarinos. A maneira utilizada para melhorar a resiliência do sistema é considerar o método de manutenção centrado na resiliência e o método de manutenção centrado na economia. É concluído que, a resiliência dos sistemas é aperfeiçoada pela utilização de uma configuração de redundância e a capacidade de absorver desastres externos é melhorada simultaneamente.

### **A.2.2 Empresas da área de Vídeo e Imagem**

### **A.2.2.1 Magic Pixel**

O uso da rede bayesiana dinâmica nesse setor foi apresentado por Zhang et al.(2008) ao aplicar essa metodologia para definir uma estrutura probabilística para alcançar uma reprodução fiel das expressões faciais dinâmicas em um modelo de rosto sintético a partir de parâmetros de animação facial MPEG-4 chamados de FAPs, considerando uma baixa taxa de bits na transmissão de dados. A rede bayesiana foi usada para unificar a análise e sintetizar a expressão facial, e na sequência, associaram os parâmetros (FAPs) a essa ação facial em uma rede bayesiana dinâmica considerando a incerteza na extração das FAPs. A vantagens associadas a esse estudo está em que as expressões faciais de aparência mais realistas podem ser reproduzidas por meio de modelagem dinâmica das expressões humanas. E também que a expressão fácil é inferida através de inferência espacial e temporal para que a percepção da qualidade da animação é menos afetada pelos FAPs detectados incorretamente.

### **A.2.2.2 Sarnoff Corporation**

A análise semântica de vídeo é baseada nos recursos de imagem de baixo nível e o conhecimento de alto nível que é codificado em representações abstratas e não geométricas. Por meio desse conhecimento, o estudo de Huang, Shih e Chao (2007) realizaram uma análise semântica em vídeos de jogos de futebol, em que aplicaram a rede bayesiana dinâmica para identificar os eventos especiais em jogos de futebol como o gol, escanteio, evento de chute, de cartão e de pênalti. O analisador de vídeo extrai as evidências de baixo nível, enquanto o analisador usando a rede bayesiana interpreta a semântica de alto nível utilizando quadros de entrada. Essa metodologia de compreensão de programas de vídeo permita que o sistema selecione os dados de baixo nível evidenciado e aplica o mecanismo de inferência pela rede bayesiana para inferir conceitos semânticos de alto nível que assim interpretam o conteúdo do programa de vídeo esportivo. A principal contribuição associada a isso é a melhoria da precisão da interpretação semântica.

## **A.2.3 Empresas da área biológica**

### **A.2.3.1 INSERM**

A previsão de resultados clínicos de doenças cerebrais ou degenerativas lesões e a avaliação dos procedimentos de reabilitação, necessitam do conhecimento das funções

cognitivas ou sensório-motoras. Essas funções são provenientes de atividades de redes de grande escala de regiões cerebrais anatomicamente conectadas. A pesquisa de Labatut et al (2004) visou compreender como a ativação de redes de grande escala deriva mecanismos e procedimentos de informações cerebrais. Ela se baseia nas técnicas de interpretação de neuroimagem e da neurociência computacional. Para isso, ela se baseia em rede bayesiana dinâmica que segue as seguintes restrições: arquitetura orientada em rede, cujo nós são estruturas cerebrais; a implementação da causalidade, a aplicação de informações no nível integrada das populações neurais, a imprecisão dos dados de neuroimagem funcional, a não linearidade e a incerteza nos mecanismos cerebrais. A não linearidade é solucionada pela implementação do filtro Kalman. Portanto, a rede bayesiana dinâmica permitiu modelar o cérebro como uma rede probabilística casual dinâmica com relacionamentos.

## **A.2.4 Empresas da área de Ciência da Computação e Matemática**

### **A.2.4.1 INRIA-Saclay**

O avanço tecnológico relacionados a redes reguladoras genéticas permite que pesquisadores biomédicos colem grandes quantidades de dados transcriptômicos, proteômicos e metabolômicos. Essa crescente disponibilidade de dados dimensionais e informações estruturadas levam a uma série de novos problemas de aprendizados, como inferência de rede. As redes se tornam uma ferramenta fundamental na biologia computacional devido à capacidade de capturar em um nível apropriado de abstrações de processo. O estudo de Michailidis e d'Alché-Buc (2013) apresentou uma revisão concentrada nas classes de modelos autorregressivas que utilizam dados de curso temporal para inferir redes reguladoras genética. A rede bayesiana dinâmica é apresentada em que são contidas informações sobre dispersão, estabilidade de causalidade, a capacidade de integrar conhecimentos prévios para utilização bem-sucedida para a tarefa de aprendizagem.

### **A.2.4.2 CSIR**

A pesquisa de Dabrowshi e De Villiers (2015) apresentou um modelo bayesiana unificado com o objetivo de realizar simultaneamente modelagem comportamental, fusão de informações e classificação. O modelo é estruturado na forma de rede bayesiana dinâmica. A modelagem comportamental é feita pelo rastreamento de forma

dinâmica e contínua de uma entidade e incorpora vários elementos contextuais que influenciam o comportamento. A entidade é classificada de acordo com o comportamento. A classificação é expressa como uma probabilidade condicional da classe de entidade dada a sua trajetória rastreada e os elementos contextuais. A inferência na rede bayesiana dinâmica é realizada usando um filtro de soma Gaussiana derivada. Para a validação desse modelo, ele foi aplicado a embarcações de acordo com o seu comportamento em uma situação de pirataria marítima.

#### **A.2.4.3 Siemens AG**

Kohler et al (2015) introduziram uma nova abordagem numérica para estimar os parâmetros das equações diferenciais usando inferência bayesiana. Esse processo tem como principal objetivo traduzir as equações em uma equação de rede bayesiana dinâmica com discretização de células probabilísticas. Para isso, houve uma reformulação para a estimativa dos parâmetros e uma combinação com o algoritmo de Boyen-koller. Esse estudo foi aplicado para um problema de Arseniato em tubulações de água, em que a partir de medições de concentração de Arseniato dissolvido na condição de contorno de saída, é inferido a força de uma fonte de Arseniato na condição de contorno de entrada.

### **A.2.5 Empresas da Indústria Química**

#### **A.2.5.1 CEDON**

Os incêndios em indústrias químicas são causadores de acidentes que foram escalonados a partir do efeito dominó. Esse efeito corresponde a acidentes que possuem alto impacto e baixa probabilidade de ocorrer. A evolução do efeito dominó relacionados com o fogo dependem dos efeitos sinérgicos, do desempenho das barreiras de segurança e também do tempo. Por isso, o estudo de Zeng et. al (2020) desenvolveram uma metodologia para fornecer probabilidades mais precisas relacionadas ao efeito dominó a partir de uma evolução temporal dos vetores escalonadores causados pelos fatores que dependem do tempo. Essa modelagem foi feita a partir da rede bayesiana dinâmica em que tinha a finalidade de propagar no espaço-tempo o padrão do efeito dominó e estimar as probabilidades dinâmicas das cadeias do efeito dominó considerando o impacto das barreiras de segurança ativas e

passivas. Com essas informações, é possível corroborar na tomada de decisões emergenciais de qualquer área da indústria química.

## **A.2.6 Empresas da Indústria Alimentícia**

### **A.2.6.1 Génie et Microbiologie des Procédés Alimentaires**

A modelagem do processo de maturação do queijo é um desafio a ser considerado devido à falta de conhecimento sobre as interações que ocorrem entre os diferentes de escala durante esse processo. Esse conhecimento pode ser obtido por meio de habilidades de cientistas e especialistas na área. Quando esse conhecimento é combinado com as informações extraídas de base de dados experimentais, isso permite uma melhor compreensão do processo de amadurecimento do queijo. Para isso, o estudo de Sicard *et. al* (2011) apresentou uma abordagem adaptando uma ciência cognitiva para extrair esse conhecimento do especialista com a coleta de dados com o modelo rede bayesiana dinâmica para o queijo camembert. Esse tipo de modelo pode ser utilizado de forma genérica para abordagens similares quando há uma falta recorrente de informações.

Influenciado pelo estudo anterior de Sicard *et. al* (2011) sobre a maturação dos queijos, o estudo de Baudrit *et al.* (2013) combinou a rede bayesiana dinâmica com as distribuições de Dirichlet para construir e atualizar incrementalmente os parâmetros gerando cada vez mais informações disponíveis, independente da sua fonte. Para essas distribuições são usadas observações empíricas, opiniões de especialistas, modelos existentes e a literatura. Na sequência, as mesmas são atualizadas utilizando inferência bayesiana, e assim, as informações a posteriori são geradas e atualizadas caso mais dados forem disponibilizados. Esse método leva em consideração a incerteza relativa ao sistema e o nível de confiança das diferentes fontes de informação. A finalidade do estudo está associada a enriquecer o modelo cada vez que novas informações são disponibilizadas, independente da fonte e do formato, a fim de melhorar a representação e proporcionar melhor compreensão dos sistemas. O estudo utilizou a aplicação para o processo de maturação do queijo camembert.

### APÊNDICE 3 – Código da proposta metodológica

Código referente a proposta metodológica do evento C, para os três intervalos de tempo, considerando opinião de especialistas e dados de alto nível para estimar os valores das taxas de falha dos eventos básicos.

Model {

#### # Tempo T1

```
for(i in 1:N) # Determinação da verossimilhança para os especialistas
{
op.A1[i] ~ dlnorm(mu.A1, tau.op.A1[i])# Variabilidade dos especialistas dada por uma
lognormal
tau.op.A1[i] <- 1/pow(log(ef.A1[i])/1.645, 2)# Determinação de tau a partir do fator de erro de
cada especialista
}
lamb.EventoA1 ~ dlnorm(mu.A1, tau.A1)
tau.A1 <- pow(log(priori.ef.A1)/1.645, -2)
priori.ef.A1 ~ dlnorm(5, 5)
mu.A1 <- log(priori.medianaA1)
priori.medianaA1 ~ dlnorm(-9.21, 0.5)
p.EventoA1 <- 1 - exp(- (lamb.EventoA1)*T1)
```

```
for(j in 1:M) # Determinação da verossimilhança para os especialistas
{
op.B1[j]~dlnorm(mu.B1, tau.op.B1[j]) # Variabilidade dos especialistas dada por uma
lognormal
tau.op.B1[j]<-1/pow(log(ef.B1[j])/1.645, 2)# Determinação de tau a partir do fator de erro de
cada especialista
}
lamb.EventoB1 ~dlnorm (mu.B1, tau.B1)
tau.B1 <- pow(log(priori.ef.B1)/1.645, -2)
priori.ef.B1 ~ dlnorm(5, 5)
mu.B1 <- log(priori.medianaB1)
priori.medianaB1 ~ dlnorm(-8.29, 0.4)
p.EventoB1 <- 1 - exp(- (lamb.EventoB1)*T1)
```

```
p.EventoC1 <- 1- ((1-(p.EventoA1*erro.insp))) * ((1-(p.EventoB1*erro.insp)))
```

#### #Barreira B1

```
for(k in 1:P) # Determinação da verossimilhança para os especialistas
{
op.D11[k] ~ dlnorm(mu.Barreira.D11, tau.op.D11[k]) # Variabilidade dos especialistas dada
por uma lognormal
tau.op.D11[k] <- 1/pow(log(ef.D11[k])/1.645, 2)# Determinação de tau a partir do fator de erro
de cada especialista
}
lamb.BarreiraD11 ~ dlnorm(mu.Barreira.D11, tau.Barreira.D11)
tau.Barreira.D11 <- pow(log(priori.ef.BarreiraD11)/1.645, -2)
priori.ef.BarreiraD11 ~ dlnorm(5, 5)
mu.Barreira.D11 <- log(priori.mediana.BarreiraD11)
```

```
priori.mediana.BarreiraD11 ~ dlnorm(-9.72, 0.6)
p.BarreiraD11 <- 1 - exp(- lamb.BarreiraD11*T1)

for(l in 1:Q) # Determinação da verossimilhança para os especialistas
{
op.E11[l] ~ dlnorm(mu.Barreira.E11, tau.op.E11[l])# Variabilidade dos especialistas dada por
uma lognormal
tau.op.E11[l] <- 1/pow(log(ef.E11[l])/1.645, 2)# Determinação de tau a partir do fator de erro
de cada especialista
}
lamb.BarreiraE11 ~ dlnorm(mu.Barreira.E11, tau.Barreira.E11)
tau.Barreira.E11 <- pow(log(priori.ef.BarreiraE11)/1.645, -2)
priori.ef.BarreiraE11 ~ dlnorm(5, 5)
mu.Barreira.E11 <- log(priori.mediana.BarreiraE11)
priori.mediana.BarreiraE11 ~ dlnorm(-9.43, 0.5)
p.BarreiraE11 <- 1 - exp(- lamb.BarreiraE11*T1)

p.Barreira11 <- (p.BarreiraD11*erro.insp)* (p.BarreiraE11*erro.insp)
```

### #Barreira B2

```
for(w in 1:R) # Determinação da verossimilhança para os especialistas
{
op.F21[w] ~ dlnorm(mu.Barreira.F21, tau.op.F21[w]) # Variabilidade dos especialistas dada por
uma lognormal
tau.op.F21[w] <- 1/pow(log(ef.F21[w])/1.645, 2)# Determinação de tau a partir do fator de erro
de cada especialista
}
lamb.BarreiraF21 ~ dlnorm(mu.Barreira.F21, tau.Barreira.F21)
mu.Barreira.F21 <- log(priori.mediana.BarreiraF21)
tau.Barreira.F21 <- pow(log(priori.ef.BarreiraF21)/1.645, -2)
priori.ef.BarreiraF21 ~ dlnorm(5, 5)
priori.mediana.BarreiraF21 ~ dlnorm(-10.82, 0.2)
p.BarreiraF21 <- 1 - exp(- lamb.BarreiraF21*T1)

for(z in 1:S) # Determinação da verossimilhança para os especialistas
{
op.G21[z] ~ dlnorm(mu.Barreira.G21, tau.op.G21[z]) # Variabilidade dos especialistas dada
por uma lognormal
tau.op.G21[z] <- 1/pow(log(ef.G21[z])/1.645, 2)# Determinação de tau a partir do fator de erro
de cada especialista
}
lamb.BarreiraG21 ~ dlnorm(mu.Barreira.G21, tau.Barreira.G21)
mu.Barreira.G21 <- log( priori.mediana.BarreiraG21)
tau.Barreira.G21 <- pow(log(priori.ef.BarreiraG21)/1.645, -2)
priori.ef.BarreiraG21 ~ dlnorm(5, 5)
priori.mediana.BarreiraG21 ~ dlnorm(-10.41, 0.2)
p.BarreiraG21 <- 1 - exp(- lamb.BarreiraG21*T1)

p.Barreira21 <- 1- ((1-(p.BarreiraF21*erro.insp))* (1-(p.BarreiraG21*erro.insp)))
```

### #Consequencias

```
p.Conseq11 <- p.EventoC1 * (1- p.Barreira11) * (1 - p.Barreira21)
p.Conseq21 <- p.EventoC1 * ( 1 - p.Barreira11) * (p.Barreira21)
```

p.Conseq31 <- p.EventoC1 \* ( p.Barreira11 ) \* (1-p.Barreira21)  
 p.Conseq41 <- p.EventoC1 \* ( p.Barreira11 ) \* (p.Barreira21)

### #Tempo T2

#### #Condicional dos eventos básicos ao longo do tempo

#### #Evento A, B e C

p.EventoA2 <- (p.EventoA1)\*(1-(p.EventoA1\*erro.insp)) + (p.EventoA1)\*erro.insp

p.EventoB2 <- (p.EventoB1)\*(1-(p.EventoB1\*erro.insp)) + (p.EventoB1)\*erro.insp

p.EventoC2 <- 1 - ((1-p.EventoA2) \* (1-p.EventoB2))

#### #Barreiras de Mitigação

#Barreira 12 ( Barreira 1 no tempo T2)

p.BarreiraD12 <- (p.BarreiraD11)\*(1-(p.BarreiraD11\*erro.insp)) + p.BarreiraD11\*erro.insp

p.BarreiraE12 <- (p.BarreiraE11)\*(1-(p.BarreiraE11\*erro.insp)) + p.BarreiraE11\*erro.insp

p.Barreira12 <- p.BarreiraD12\* p.BarreiraE12

#### #Barreira 22 ( Barreira 2 no tempo T2)

p.BarreiraF22 <- (p.BarreiraF21)\*(1-(p.BarreiraF21\*erro.insp)) + p.BarreiraF21\*erro.insp

p.BarreiraG22 <- (p.BarreiraG21)\*(1-(p.BarreiraG21\*erro.insp)) + p.BarreiraG21\*erro.insp

p.Barreira22 <- 1 - ((1-p.BarreiraF22)\* (1-p.BarreiraG22))

#### #Árvore de Evento

#### #Para o tempo T2

p.Conseq12 <- p.EventoC2 \* (1- p.Barreira12) \* (1 - p.Barreira22)

p.Conseq22 <- p.EventoC2 \* ( 1 - p.Barreira12) \* (p.Barreira22)

p.Conseq32 <- p.EventoC2 \* ( p.Barreira12) \* (1-p.Barreira22)

p.Conseq42 <- p.EventoC2 \* ( p.Barreira12) \* (p.Barreira22)

### #Evento T3

#### #Evento C

#### #Condicional dos eventos básicos ao longo do tempo

#### #Evento A,B e C

x.C3 ~ dbin(p.EventoC3, n.EventoC3)

p.EventoA3 <- (p.EventoA1)\*(1-p.EventoA2) + p.EventoA2

p.EventoB3 <- (p.EventoB1)\*(1-p.EventoB2) + p.EventoB2

p.EventoC3 <- 1 - ((1-p.EventoA3) \* (1-p.EventoB3))

**#Barreiras de Mitigação****#Barreira 13**

```
x.Barreira13 ~ dbin(p.Barreira13, n.Barreira13)
p.BarreiraD13 <- (p.BarreiraD11)*(1-p.BarreiraD12) + p.BarreiraD12
p.BarreiraE13 <- (p.BarreiraE11)*(1-p.BarreiraE12) + p.BarreiraE12
p.Barreira13 <- p.BarreiraD13* p.BarreiraE13
```

**#Barreira 23**

```
x.Barreira23 ~ dbin(p.Barreira23, n.Barreira23)
p.BarreiraF23 <- (p.BarreiraF21)*(1-p.BarreiraF22) + p.BarreiraF22
p.BarreiraG23 <- (p.BarreiraG21)*(1-p.BarreiraG22) + p.BarreiraG22
p.Barreira23 <- 1- ((1-p.BarreiraF23)* (1-p.BarreiraG23))
```

**#Árvore de Evento****#Para o tempo T3**

```
x.Conseq13 ~ dbin(p.Conseq13, n.Conseq13)
x.Conseq23 ~ dbin(p.Conseq23, n.Conseq23)
x.Conseq33 ~ dbin(p.Conseq33, n.Conseq33)
x.Conseq43 ~ dbin(p.Conseq43, n.Conseq43)

p.Conseq13 <- p.EventoC3 * ( 1 - p.Barreira13) * (1 - p.Barreira23)
p.Conseq23 <- p.EventoC3 * ( 1 - p.Barreira13) * (p.Barreira23)
p.Conseq33 <- p.EventoC3 * ( p.Barreira13) * (1 - p.Barreira23)
p.Conseq43 <- p.EventoC3 * ( p.Barreira13) * (p.Barreira23)
```

```
}
```

**Data**

```
list( x.C3= 4, n.EventoC3= 20, T1= 400, x.Barreira13 = 2 , x.Barreira23 = 1, n.Barreira13 = 20,
n.Barreira23 = 20, x.Conseq13 = 2, x.Conseq23= 0, x.Conseq33=1, x.Conseq43=1, n.Conseq13
= 20, n.Conseq23=20, n.Conseq33=20, n.Conseq43=20, N = 5, M = 5, P=5, Q=5, R=5, S=5,
op.A1 = c(1.2E-4, 2.0E-4, 1.53E-4, 0.8E-4, 1.1E-4), ef.A1 = c(2,2,2,2,2), op.B1 = c(1.5E-4,
2.0E-4, 3.0E-4, 2.7E-4, 2.3E-4), ef.B1 = c(2,2,2,2,2), op.D11 =c(5.5E-5, 6.0E-5,6.2E-5,5.8E-5,
6.2E-5), op.E11 = c(7.8E-5, 8.2E-5, 8.0E-5,8.4E-5, 7.9E-5), op.F21 = c(1.7E-5, 2.2E-5, 1.8E-5,
2.5E-5,2.0E-5), op.G21 = c(3.5E-5, 2.5E-5, 3.0E-5, 3.8E-5, 2.8E-5), ef.D11 = c(2,2,2,2,2),
ef.E11 = c(2,2,2,2,2), ef.F21 = c(2,2,2,2,2), ef.G21 = c(2,2,2,2,2), erro.insp =0.2)
```

#### APÊNDICE 4 – Código da hipótese de aplicação para a Hipótese 3

Código referente a hipótese de aplicação do evento de quebra de *riser*, com apenas um intervalo de tempo (Hipótese 3), considerando opinião de especialistas e dados de alto nível para estimar os valores das taxas de falha dos eventos básicos.

```

Model {
# Tempo T1

x.QuebraRiser ~ dbin(p.QuebraRiser, n.QuebraRiser)

for(i in 1:N) # Determinação da verrossimilhança para os especialistas
{
op.Base1[i] ~ dlnorm(mu.Base1, tau.op.Base1[i]) # Variabilidade dos especialistas dada por
uma lognormal
tau.op.Base1[i] <- 1/pow(log(ef.Base1[i])/1.645, 2) # Determinação de tau a partir do fator de
erro de cada especialista
}
lamb.EventoBase1 ~ dlnorm (mu.Base1, tau.Base1)
tau.Base1 <- pow(log(priori.ef.Base1)/1.645, -2)
priori.ef.Base1 ~ dlnorm(5, 5)
mu.Base1 <- log(priori.medianaBase1)
priori.medianaBase1 ~ dlnorm(-15.99, 4)
p.EventoBase1 <- 1 - exp(- lamb.EventoBase1*T1)

for(j in 1:M) # Determinação da verrossimilhança para os especialistas
{
op.Base2[j]~dlnorm(mu.Base2, tau.op.Base2[j]) # Variabilidade dos especialistas dada por uma
lognormal
tau.op.Base2[j] <-1/pow(log(ef.Base2[j])/1.645, 2) # Determinação de tau a partir do fator de
erro de cada especialista
}
lamb.EventoBase2 ~dlnorm (mu.Base2, tau.Base2)
tau.Base2 <- pow(log(priori.ef.Base2)/1.645, -2)
priori.ef.Base2 ~ dlnorm(5, 5)
mu.Base2 <- log(priori.medianaBase2)
priori.medianaBase2 ~ dlnorm(-15.95, 4)
p.EventoBase2 <- 1 - exp(- lamb.EventoBase2*T1)

for(k in 1:O) # Determinação da verrossimilhança para os especialistas
{
op.Base3[k]~dlnorm(mu.Base3, tau.op.Base3[k]) # Variabilidade dos especialistas dada por
uma lognormal
tau.op.Base3[k]<-1/pow(log(ef.Base3[k])/1.645, 2) # Determinação de tau a partir do fator de
erro de cada especialista
}
lamb.EventoBase3 ~dlnorm (mu.Base3, tau.Base3)
tau.Base3 <- pow(log(priori.ef.Base3)/1.645, -2)
priori.ef.Base3 ~ dlnorm(5, 5)
mu.Base3 <- log(priori.medianaBase3)
priori.medianaBase3 ~ dlnorm(-16.16, 4)
p.EventoBase3 <- 1 - exp(- lamb.EventoBase3*T1)

for(l in 1:P) # Determinação da verrossimilhança para os especialistas

```

```

{
op.Base4[l]~dlnorm(mu.Base4, tau.op.Base4[l]) # Variabilidade dos especialistas dada por uma
lognormal
tau.op.Base4[l]<-1/pow(log(ef.Base4[l])/1.645, 2)# Determinação de tau a partir do fator de erro
de cada especialista
}
lamb.EventoBase4 ~dlnorm (mu.Base4, tau.Base4)
tau.Base4 <- pow(log(priori.ef.Base4)/1.645, -2)
priori.ef.Base4 ~ dlnorm(5, 5)
mu.Base4 <- log(priori.medianaBase4)
priori.medianaBase4 ~ dlnorm(-15.56, 4)
p.EventoBase4 <- 1 - exp(- lamb.EventoBase4*T1)

for(m in 1:Q) # Determinação da verrossimilhança para os especialistas
{
op.Base6[m]~dlnorm(mu.Base6, tau.op.Base6[m]) # Variabilidade dos especialistas dada por
uma lognormal
tau.op.Base6[m]<-1/pow(log(ef.Base6[m])/1.645, 2)# Determinação de tau a partir do fator de
erro de cada especialista
}
lamb.EventoBase6 ~dlnorm (mu.Base6, tau.Base6)
tau.Base6 <- pow(log(priori.ef.Base6)/1.645, -2)
priori.ef.Base6 ~ dlnorm(5, 5)
mu.Base6 <- log(priori.medianaBase6)
priori.medianaBase6 ~ dlnorm(-15.24, 4)
p.EventoBase6 <- 1 - exp(- lamb.EventoBase6 *T1)

for(n in 1:R) # Determinação da verrossimilhança para os especialistas
{
op.Base7[n]~dlnorm(mu.Base7, tau.op.Base7[n]) # Variabilidade dos especialistas dada por
uma lognormal
tau.op.Base7[n]<-1/pow(log(ef.Base7[n])/1.645, 2)# Determinação de tau a partir do fator de
erro de cada especialista
}
lamb.EventoBase7 ~dlnorm (mu.Base7, tau.Base7)
tau.Base7 <- pow(log(priori.ef.Base7)/1.645, -2)
priori.ef.Base7 ~ dlnorm(5, 5)
mu.Base7 <- log(priori.medianaBase7)
priori.medianaBase7 ~ dlnorm(-14.35, 4)
p.EventoBase7 <- 1 - exp(- lamb.EventoBase6 *T1)

for(o in 1:S) # Determinação da verrossimilhança para os especialistas
{
op.Base8[o]~dlnorm(mu.Base8, tau.op.Base8[o]) # Variabilidade dos especialistas dada por
uma lognormal
tau.op.Base8[o]<-1/pow(log(ef.Base8[o])/1.645, 2)# Determinação de tau a partir do fator de
erro de cada especialista
}
lamb.EventoBase8 ~dlnorm (mu.Base8, tau.Base8)
tau.Base8 <- pow(log(priori.ef.Base8)/1.645, -2)
priori.ef.Base8 ~ dlnorm(5, 5)
mu.Base8 <- log(priori.medianaBase8)
priori.medianaBase8 ~ dlnorm(-13.75, 3)
p.EventoBase8 <- 1 - exp(- lamb.EventoBase8 *T1)

```

```

for(p in 1:T) # Determinação da verossimilhança para os especialistas
{
op.Base9[p]~dlnorm(mu.Base9, tau.op.Base9[p]) # Variabilidade dos especialistas dada por
uma lognormal
tau.op.Base9[p]<-1/pow(log(ef.Base9[p])/1.645, 2)# Determinação de tau a partir do fator de
erro de cada especialista
}
lamb.EventoBase9 ~dlnorm (mu.Base9, tau.Base9)
tau.Base9 <- pow(log(priori.ef.Base9)/1.645, -2)
priori.ef.Base9 ~ dlnorm(5, 5)
mu.Base9 <- log(priori.medianaBase9)
priori.medianaBase9 ~ dlnorm(-15.24, 4)
p.EventoBase9 <- 1 - exp(- lamb.EventoBase9 *T1)

for(q in 1:U) # Determinação da verossimilhança para os especialistas
{
op.Base10[q]~dlnorm(mu.Base10, tau.op.Base10[q]) # Variabilidade dos especialistas dada por
uma lognormal
tau.op.Base10[q]<-1/pow(log(ef.Base10[q])/1.645, 2)# Determinação de tau a partir do fator de
erro de cada especialista
}
lamb.EventoBase10 ~dlnorm (mu.Base10, tau.Base10)
tau.Base10 <- pow(log(priori.ef.Base10)/1.645, -2)
priori.ef.Base10 ~ dlnorm(5, 5)
mu.Base10 <- log(priori.medianaBase10)
priori.medianaBase10 ~ dlnorm(-15.82, 4)
p.EventoBase10 <- 1 - exp(- lamb.EventoBase10 *T1)

for(r in 1:V) # Determinação da verossimilhança para os especialistas
{
op.Base11[r]~dlnorm(mu.Base11, tau.op.Base11[r]) # Variabilidade dos especialistas dada por
uma lognormal
tau.op.Base11[r]<-1/pow(log(ef.Base11[r])/1.645, 2)# Determinação de tau a partir do fator de
erro de cada especialista
}
lamb.EventoBase11 ~dlnorm (mu.Base11, tau.Base11)
tau.Base11 <- pow(log(priori.ef.Base11)/1.645, -2)
priori.ef.Base11 ~ dlnorm(5, 5)
mu.Base11 <- log(priori.medianaBase11)
priori.medianaBase11 ~ dlnorm(-15.74, 4)
p.EventoBase11 <- 1 - exp(- lamb.EventoBase11 *T1)

for(s in 1:X) # Determinação da verossimilhança para os especialistas
{
op.Base12[s]~dlnorm(mu.Base12, tau.op.Base12[s]) # Variabilidade dos especialistas dada por
uma lognormal
tau.op.Base12[s]<-1/pow(log(ef.Base12[s])/1.645, 2)# Determinação de tau a partir do fator de
erro de cada especialista
}
lamb.EventoBase12 ~dlnorm (mu.Base12, tau.Base12)
tau.Base12 <- pow(log(priori.ef.Base12)/1.645, -2)
priori.ef.Base12 ~ dlnorm(5, 5)
mu.Base12 <- log(priori.medianaBase12)
priori.medianaBase12 ~ dlnorm(-15.33, 4)
p.EventoBase12 <- 1 - exp(- lamb.EventoBase12 *T1)

```

**#Evento "Falha do Corpo" é um portão OR e "Falha Intrínseca do Riser" é um portão OR**

$p.FalhadoCorpo <- p.EventoBase10 + p.EventoBase11 + p.EventoBase12 - (p.EventoBase10 * p.EventoBase11) - (p.EventoBase10 * p.EventoBase12) - (p.EventoBase11 * p.EventoBase12) + (p.EventoBase10 * p.EventoBase11 * p.EventoBase12)$

$p.FalhaIntrinseca <- p.EventoBase9 + p.FalhadoCorpo - (p.EventoBase9 * p.FalhadoCorpo)$

**#Evento "Falha de Pressurização" é um portão OR e "Falha dos Tensionadores" é um portão OR**

$p.FalhaPressurizacao <- p.EventoBase2 + p.EventoBase3 + p.EventoBase4 - (p.EventoBase2 * p.EventoBase3) - (p.EventoBase2 * p.EventoBase4) - (p.EventoBase3 * p.EventoBase4) + (p.EventoBase2 * p.EventoBase3 * p.EventoBase4)$

$p.FalhaTensionadores <- p.EventoBase1 + p.FalhaPressurizacao - (p.EventoBase1 * p.FalhaPressurizacao)$

**#Evento "Drift off com falha de EDS" é um portão AND, "Drive off com falha de EDS" é um portão AND e o evento "Perda de Posição" é um portão OR**

$p.PerdaPosicao <- p.EventoBase6 * p.EventoBase7 * (1 - p.EventoBase8) + p.EventoBase8 * p.EventoBase7 * (1 - p.EventoBase6) + p.EventoBase8 * p.EventoBase7 * p.EventoBase6$

**#Evento "Quebra de Riser" é um portão OR**

$p.QuebraRiser <- p.FalhaIntrinseca + p.FalhaTensionadores + p.PerdaPosicao - (p.FalhaIntrinseca * p.FalhaTensionadores) - (p.FalhaIntrinseca * p.PerdaPosicao) - (p.FalhaTensionadores * p.PerdaPosicao) + (p.FalhaIntrinseca * p.PerdaPosicao * p.FalhaTensionadores)$

**#Barreira 11 - Barreira Deadman/Autoshear  
# Barreira 11 é a Barreira 1 no tempo T1 com portão OR**

$x.Barreira11 \sim dbin(p.Barreira11, n.Barreira11)$

for(t in 1:Y) # Determinação da verossimilhança para os especialistas

```
{
op.Acionamento11[t] ~ dlnorm(mu.Barreira.Acionamento11, tau.op.Acionamento11[t]) #
Variabilidade dos especialistas dada por uma lognormal
tau.op.Acionamento11[t] <- 1/pow(log(ef.Acionamento11[t])/1.645, 2)# Determinação de tau a
partir do fator de erro de cada especialista
}
```

$\text{lamb.BarreiraAcionamento11} \sim \text{dlnorm}(\text{mu.Barreira.Acionamento11}, \text{tau.Barreira.Acionamento11})$

$\text{tau.Barreira.Acionamento11} <- \text{pow}(\text{log}(\text{priori.ef.BarreiraAcionamento11})/1.645, -2)$

$\text{priori.ef.BarreiraAcionamento11} \sim \text{dlnorm}(5, 5)$

$\text{mu.Barreira.Acionamento11} <- \text{log}(\text{priori.mediana.BarreiraAcionamento11})$

$\text{priori.mediana.BarreiraAcionamento11} \sim \text{dlnorm}(-12.72, 5)$

$p.BarreiraAcionamento11 <- 1 - \text{exp}(- \text{lamb.BarreiraAcionamento11} * T1)$

for(u in 1:Z) # Determinação da verossimilhança para os especialistas

```
{
```

```

op.Sistema11[u] ~ dlnorm(mu.Barreira.Sistema11, tau.op.Sistema11[u])# Variabilidade dos
especialistas dada por uma lognormal
tau.op.Sistema11[u] <- 1/pow(log(ef.Sistema11[u])/1.645, 2)# Determinação de tau a partir do
fator de erro de cada especialista
}
lamb.BarreiraSistema11 ~ dlnorm(mu.Barreira.Sistema11, tau.Barreira.Sistema11)
tau.Barreira.Sistema11 <- pow(log(priori.ef.BarreiraSistema11)/1.645, -2)
priori.ef.BarreiraSistema11 ~ dlnorm(5, 5)
mu.Barreira.Sistema11 <- log(priori.mediana.BarreiraSistema11)
priori.mediana.BarreiraSistema11 ~ dlnorm(-9.69, 0.6)
p.BarreiraSistema11 <- 1 - exp(- lamb.BarreiraSistema11*T1)

p.Barreira11 <- p.BarreiraAcionamento11 + p.BarreiraSistema11 - (p.BarreiraAcionamento11*
p.BarreiraSistema11)

```

### **#Barreira 21 - Sistema Acústico**

#### **# Barreira 21 é a Barreira 2 no tempo T1 com portão OR**

```

x.Barreira21 ~ dbin(p.Barreira21, n.Barreira21)

for(v in 1:A) # Determinação da verossimilhança para os especialistas
{
op.Acionamento21[v] ~ dlnorm(mu.Barreira.Acionamento21, tau.op.Acionamento21[v]) #
Variabilidade dos especialistas dada por uma lognormal
tau.op.Acionamento21[v] <- 1/pow(log(ef.Acionamento21[v])/1.645, 2)# Determinação de tau a
partir do fator de erro de cada especialista
}
lamb.BarreiraAcionamento21 ~ dlnorm(mu.Barreira.Acionamento21,
tau.Barreira.Acionamento21)
tau.Barreira.Acionamento21 <- pow(log(priori.ef.BarreiraAcionamento21)/1.645, -2)
priori.ef.BarreiraAcionamento21 ~ dlnorm(5, 5)
mu.Barreira.Acionamento21 <- log(priori.mediana.BarreiraAcionamento21)
priori.mediana.BarreiraAcionamento21 ~dlnorm( -12.72, 5)
p.BarreiraAcionamento21 <- 1 - exp(- lamb.BarreiraAcionamento21*T1)

for(x in 1:B) # Determinação da verossimilhança para os especialistas
{
op.Sistema21[x] ~ dlnorm(mu.Barreira.Sistema21, tau.op.Sistema21[x] ) # Variabilidade dos
especialistas dada por uma lognormal
tau.op.Sistema21[x] <- 1/pow(log(ef.Sistema21[x])/1.645, 2)# Determinação de tau a partir do
fator de erro de cada especialista
}
lamb.BarreiraSistema21 ~ dlnorm(mu.Barreira.Sistema21, tau.Barreira.Sistema21)
tau.Barreira.Sistema21 <- pow(log(priori.ef.BarreiraSistema21)/1.645, -2)
priori.ef.BarreiraSistema21 ~ dlnorm(5, 5)
mu.Barreira.Sistema21 <- log(priori.mediana.BarreiraSistema21)
priori.mediana.BarreiraSistema21 ~ dlnorm(-9.43, 0.5)
p.BarreiraSistema21 <- 1 - exp(- lamb.BarreiraSistema21*T1)

p.Barreira21 <- p.BarreiraAcionamento21 + p.BarreiraSistema21 - (p.BarreiraAcionamento21*
p.BarreiraSistema21)

```

### **#Árvore de Evento**

#### **#Para o tempo T1**

### # Conseq11 é a consequência 1 para o tempo T1

```

x.Conseq11 ~ dbin(p.Conseq11, n.Conseq11)
x.Conseq21 ~ dbin(p.Conseq21, n.Conseq21)
x.Conseq31 ~ dbin(p.Conseq31, n.Conseq31)

p.Conseq11 <- p.QuebraRiser * (1- p.Barreira11)
p.Conseq21 <-p.QuebraRiser* (p.Barreira11) * (1- p.Barreira21)
p.Conseq31 <- p.QuebraRiser * (p.Barreira11) * (p.Barreira21)

}

Data
list( x.QuebraRiser = 1,
n.QuebraRiser = 43 , op.Base1 = c(1.0E-7, 0.8E-7, 1.2E-7, 0.7E-7, 1.5E-7), ef.Base1 =
c(2,2,2,2,2), op.Base2 = c(1.0E-7, 1.3E-7, 0.9E-7, 1.15E-7, 1.2E-7), ef.Base2 = c(2,2,2,2,2),
op.Base3 = c(9.5E-8, 9.0E-8, 9.8E-8, 9.2E-8, 9.6E-8), ef.Base3 = c(2,2,2,2,2),
op.Base4 = c(2.0E-7, 1.5E-7, 1.8E-7, 1.6E-7, 1.9E-7), ef.Base4 = c(2,2,2,2,2),
op.Base6 = c(2.0E-7, 2.2E-7, 2.5E-7, 2.8E-7, 2.3E-7), ef.Base6 = c(2,2,2,2,2),
op.Base7 = c(5.5E-7, 5.3E-7, 5.9E-7, 6.9E-7, 5.2E-7), ef.Base7 = c(2,2,2,2,2),
op.Base8 = c(1.1E-6, 1.0E-6, 0.8E-6, 0.5E-6, 1.2E-6), ef.Base8 = c(2,2,2,2,2),
op.Base9 = c(2.0E-7, 2.5E-7, 2.8E-7, 2.4E-7, 1.5E-7), ef.Base9 = c(2,2,2,2,2),
op.Base10 = c(1.0E-7, 1.5E-7, 1.3E-7, 2.0E-7, 1.1E-7), ef.Base10 = c(2,2,2,2,2),
op.Base11 = c(1.5E-7, 1.0E-7, 2.0E-7, 0.8E-7, 1.8E-7), ef.Base11 = c(2,2,2,2,2),
op.Base12 = c(2.0E-7, 2.5E-7, 2.8E-7, 1.0E-7, 1.8E-7),ef.Base12 = c(2,2,2,2,2),
N = 5, M = 5, O = 5, P=5, Q= 5, R = 5, S=5, T = 5, U=5, V=5, X = 5, Y =5, Z = 5, A = 5, B = 5,
op.Acionamento11 = c(3.0E-6, 2.5E-6, 2.8E-6, 3.3E-6, 3.5E-6), ef.Acionamento11 =
c(2,2,2,2,2), op.Sistema11 = c(6.0E-5, 6.5E-5, 6.2E-5, 5.8E-5, 5.5E-5),
ef.Sistema11 = c(2,2,2,2,2), op.Acionamento21 = c(3.0E-6, 2.5E-6, 2.8E-6, 3.3E-6, 3.5E-6),
ef.Acionamento21 =c(2,2,2,2,2), op.Sistema21 = c(8.0E-5, 8.5E-5, 7.5E-5, 7.8E-5, 8.2E-5),
ef.Sistema21 = c(2,2,2,2,2), T1= 2016,
x.Conseq11 = 0,
x.Conseq21 = 1,
x.Conseq31 = 0,
n.Conseq11 = 43,
n.Conseq21 = 43,
n.Conseq31 = 43,
x.Barreira11 =1,
x.Barreira21 =0,
n.Barreira11 = 45,
n.Barreira21 = 67)

```

## APÊNDICE 5 – Código da hipótese de aplicação para a Hipótese 4

Código referente a hipótese de aplicação do evento de quebra de riser, com todos os 3 intervalos de tempo (Hipótese 4), considerando opinião de especialistas e dados de alto nível para estimar os valores das taxas de falha dos eventos básicos.

Model {

### # Tempo T1

```

for(i in 1:N) # Determinação da verossimilhança para os especialistas
{
op.Base1[i] ~ dlnorm(mu.Base1, tau.op.Base1[i]) # Variabilidade dos especialistas dada por
uma lognormal
tau.op.Base1[i] <- 1/pow(log(ef.Base1[i])/1.645, 2) # Determinação de tau a partir do fator de
erro de cada especialista
}
lamb.EventoBase1 ~ dlnorm (mu.Base1, tau.Base1)
tau.Base1 <- pow(log(priori.ef.Base1)/1.645, -2)
priori.ef.Base1 ~ dlnorm(5, 5)
mu.Base1 <- log(priori.medianaBase1)
priori.medianaBase1 ~ dlnorm(-15.99, 4)
p.EventoBase1 <- 1 - exp(- lamb.EventoBase1*T1)

for(j in 1:M) # Determinação da verossimilhança para os especialistas
{
op.Base2[j]~dlnorm(mu.Base2, tau.op.Base2[j]) # Variabilidade dos especialistas dada por uma
lognormal
tau.op.Base2[j] <- 1/pow(log(ef.Base2[j])/1.645, 2) # Determinação de tau a partir do fator de
erro de cada especialista
}
lamb.EventoBase2 ~dlnorm (mu.Base2, tau.Base2)
tau.Base2 <- pow(log(priori.ef.Base2)/1.645, -2)
priori.ef.Base2 ~ dlnorm(5, 5)
mu.Base2 <- log(priori.medianaBase2)
priori.medianaBase2 ~ dlnorm(-15.95, 4)
p.EventoBase2 <- 1 - exp(- lamb.EventoBase2*T1)

for(k in 1:O) # Determinação da verossimilhança para os especialistas
{
op.Base3[k]~dlnorm(mu.Base3, tau.op.Base3[k]) # Variabilidade dos especialistas dada por
uma lognormal
tau.op.Base3[k]<-1/pow(log(ef.Base3[k])/1.645, 2) # Determinação de tau a partir do fator de
erro de cada especialista
}
lamb.EventoBase3 ~dlnorm (mu.Base3, tau.Base3)
tau.Base3 <- pow(log(priori.ef.Base3)/1.645, -2)
priori.ef.Base3 ~ dlnorm(5, 5)
mu.Base3 <- log(priori.medianaBase3)
priori.medianaBase3 ~ dlnorm(-16.16, 4)
p.EventoBase3 <- 1 - exp(- lamb.EventoBase3*T1)

for(l in 1:P) # Determinação da verossimilhança para os especialistas
{

```

```

op.Base4[l]~dlnorm(mu.Base4, tau.op.Base4[l]) # Variabilidade dos especialistas dada por uma
lognormal
tau.op.Base4[l]<-1/pow(log(ef.Base4[l])/1.645, 2)# Determinação de tau a partir do fator de erro
de cada especialista
}
lamb.EventoBase4 ~dlnorm (mu.Base4, tau.Base4)
tau.Base4 <- pow(log(priori.ef.Base4)/1.645, -2)
priori.ef.Base4 ~ dlnorm(5, 5)
mu.Base4 <- log(priori.medianaBase4)
priori.medianaBase4 ~ dlnorm(-15.56, 4)
p.EventoBase4 <- 1 - exp(- lamb.EventoBase4*T1)

for(m in 1:Q) # Determinação da verrossimilhança para os especialistas
{
op.Base6[m]~dlnorm(mu.Base6, tau.op.Base6[m]) # Variabilidade dos especialistas dada por
uma lognormal
tau.op.Base6[m]<-1/pow(log(ef.Base6[m])/1.645, 2)# Determinação de tau a partir do fator de
erro de cada especialista
}
lamb.EventoBase6 ~dlnorm (mu.Base6, tau.Base6)
tau.Base6 <- pow(log(priori.ef.Base6)/1.645, -2)
priori.ef.Base6 ~ dlnorm(5, 5)
mu.Base6 <- log(priori.medianaBase6)
priori.medianaBase6 ~ dlnorm(-15.24, 4)
p.EventoBase6 <- 1 - exp(- lamb.EventoBase6 *T1)

for(n in 1:R) # Determinação da verrossimilhança para os especialistas
{
op.Base7[n]~dlnorm(mu.Base7, tau.op.Base7[n]) # Variabilidade dos especialistas dada por
uma lognormal
tau.op.Base7[n]<-1/pow(log(ef.Base7[n])/1.645, 2)# Determinação de tau a partir do fator de
erro de cada especialista
}
lamb.EventoBase7 ~dlnorm (mu.Base7, tau.Base7)
tau.Base7 <- pow(log(priori.ef.Base7)/1.645, -2)
priori.ef.Base7 ~ dlnorm(5, 5)
mu.Base7 <- log(priori.medianaBase7)
priori.medianaBase7 ~ dlnorm(-14.35, 4)
p.EventoBase7 <- 1 - exp(- lamb.EventoBase6 *T1)

for(o in 1:S) # Determinação da verrossimilhança para os especialistas
{
op.Base8[o]~dlnorm(mu.Base8, tau.op.Base8[o]) # Variabilidade dos especialistas dada por
uma lognormal
tau.op.Base8[o]<-1/pow(log(ef.Base8[o])/1.645, 2)# Determinação de tau a partir do fator de
erro de cada especialista
}
lamb.EventoBase8 ~dlnorm (mu.Base8, tau.Base8)
tau.Base8 <- pow(log(priori.ef.Base8)/1.645, -2)
priori.ef.Base8 ~ dlnorm(5, 5)
mu.Base8 <- log(priori.medianaBase8)
priori.medianaBase8 ~ dlnorm(-13.75, 3)
p.EventoBase8 <- 1 - exp(- lamb.EventoBase8 *T1)

for(p in 1:T) # Determinação da verrossimilhança para os especialistas

```

```

{
op.Base9[p]~dlnorm(mu.Base9, tau.op.Base9[p]) # Variabilidade dos especialistas dada por
uma lognormal
tau.op.Base9[p]<-1/pow(log(ef.Base9[p])/1.645, 2)# Determinação de tau a partir do fator de
erro de cada especialista
}
lamb.EventoBase9 ~dlnorm (mu.Base9, tau.Base9)
tau.Base9 <- pow(log(priori.ef.Base9)/1.645, -2)
priori.ef.Base9 ~ dlnorm(5, 5)
mu.Base9 <- log(priori.medianaBase9)
priori.medianaBase9 ~ dlnorm(-15.24, 4)
p.EventoBase9 <- 1 - exp(- lamb.EventoBase9 *T1)

for(q in 1:U) # Determinação da verrossimilhança para os especialistas
{
op.Base10[q]~dlnorm(mu.Base10, tau.op.Base10[q]) # Variabilidade dos especialistas dada por
uma lognormal
tau.op.Base10[q]<-1/pow(log(ef.Base10[q])/1.645, 2)# Determinação de tau a partir do fator de
erro de cada especialista
}
lamb.EventoBase10 ~dlnorm (mu.Base10, tau.Base10)
tau.Base10 <- pow(log(priori.ef.Base10)/1.645, -2)
priori.ef.Base10 ~ dlnorm(5, 5)
mu.Base10 <- log(priori.medianaBase10)
priori.medianaBase10 ~ dlnorm(-15.82, 4)
p.EventoBase10 <- 1 - exp(- lamb.EventoBase10 *T1)

for(r in 1:V) # Determinação da verrossimilhança para os especialistas
{
op.Base11[r]~dlnorm(mu.Base11, tau.op.Base11[r]) # Variabilidade dos especialistas dada por
uma lognormal
tau.op.Base11[r]<-1/pow(log(ef.Base11[r])/1.645, 2)# Determinação de tau a partir do fator de
erro de cada especialista
}
lamb.EventoBase11 ~dlnorm (mu.Base11, tau.Base11)
tau.Base11 <- pow(log(priori.ef.Base11)/1.645, -2)
priori.ef.Base11 ~ dlnorm(5, 5)
mu.Base11 <- log(priori.medianaBase11)
priori.medianaBase11 ~ dlnorm(-15.74, 4)
p.EventoBase11 <- 1 - exp(- lamb.EventoBase11 *T1)

for(s in 1:X) # Determinação da verrossimilhança para os especialistas
{
op.Base12[s]~dlnorm(mu.Base12, tau.op.Base12[s]) # Variabilidade dos especialistas dada por
uma lognormal
tau.op.Base12[s]<-1/pow(log(ef.Base12[s])/1.645, 2)# Determinação de tau a partir do fator de
erro de cada especialista
}
lamb.EventoBase12 ~dlnorm (mu.Base12, tau.Base12)
tau.Base12 <- pow(log(priori.ef.Base12)/1.645, -2)
priori.ef.Base12 ~ dlnorm(5, 5)
mu.Base12 <- log(priori.medianaBase12)
priori.medianaBase12 ~ dlnorm(-15.33, 4)
p.EventoBase12 <- 1 - exp(- lamb.EventoBase12 *T1)

```

**#Evento "Falha do Corpo" é um portão OR e "Falha Intrínseca do Riser" é um portão OR**

```
p.FalhadoCorpo <- p.EventoBase10*erro.insp + p.EventoBase11*erro.insp +
p.EventoBase12*erro.insp - (p.EventoBase10*erro.insp * p.EventoBase11*erro.insp) -
(p.EventoBase10*erro.insp * p.EventoBase12*erro.insp) - (p.EventoBase11*erro.insp *
p.EventoBase12*erro.insp) + (p.EventoBase10*erro.insp * p.EventoBase11*erro.insp *
p.EventoBase12*erro.insp)
```

```
p.FalhaIntrinseca <- p.EventoBase9*erro.insp + p.FalhadoCorpo - (p.EventoBase9*erro.insp *
p.FalhadoCorpo)
```

**#Evento "Falha de Pressurização" é um portão OR e "Falha dos Tensionadores" é um portão OR**

```
p.FalhaPressurizacao <- p.EventoBase2*erro.insp + p.EventoBase3*erro.insp+
p.EventoBase4*erro.insp - (p.EventoBase2 *erro.insp *p.EventoBase3*erro.insp) -
(p.EventoBase2*erro.insp * p.EventoBase4*erro.insp) - (p.EventoBase3*erro.insp *
p.EventoBase4*erro.insp) + (p.EventoBase2*erro.insp * p.EventoBase3*erro.insp *
p.EventoBase4*erro.insp)
```

```
p.FalhaTensionadores <- p.EventoBase1*erro.insp + p.FalhaPressurizacao -
(p.EventoBase1*erro.insp* p.FalhaPressurizacao)
```

**#Evento "Drift off com falha de EDS" é um portão AND, "Drive off com falha de EDS" é um portão AND e o evento "Perda de Posição" é um portão OR**

```
p.PerdaPosicao <- p.EventoBase6*erro.insp * p.EventoBase7*erro.insp * (1-
p.EventoBase8*erro.insp) + p.EventoBase8 *erro.insp* p.EventoBase7*erro.insp* (1-
p.EventoBase6*erro.insp) + p.EventoBase8*erro.insp * p.EventoBase7*erro.insp*
p.EventoBase6*erro.insp
```

**#Evento "Quebra de Riser" é um portão OR**

```
p.QuebraRiser <- p.FalhaIntrinseca + p.FalhaTensionadores + p.PerdaPosicao - (
p.FalhaIntrinseca * p.FalhaTensionadores) - (p.FalhaIntrinseca * p.PerdaPosicao) -
(p.FalhaTensionadores * p.PerdaPosicao)+ (p.FalhaIntrinseca * p.PerdaPosicao *
p.FalhaTensionadores)
```

**#Barreira 11 - Barreira Deadman/Autoshear**

**# Barreira 11 é a Barreira 1 no tempo T1 com portão OR**

```
for(t in 1:Y) # Determinação da verrossimilhança para os especialistas
```

```
{
op.Acionamento11[t] ~ dlnorm(mu.Barreira.Acionamento11, tau.op.Acionamento11[t]) #
Variabilidade dos especialistas dada por uma lognormal
tau.op.Acionamento11[t] <- 1/pow(log(ef.Acionamento11[t])/1.645, 2)# Determinação de tau a
partir do fator de erro de cada especialista
}
```

```
lamb.BarreiraAcionamento11 ~ dlnorm(mu.Barreira.Acionamento11,
tau.Barreira.Acionamento11)
```

```
tau.Barreira.Acionamento11 <- pow(log(priori.ef.BarreiraAcionamento11)/1.645, -2)
```

```
priori.ef.BarreiraAcionamento11 ~ dlnorm(5, 5)
```

```
mu.Barreira.Acionamento11 <- log(priori.mediana.BarreiraAcionamento11)
```

```
priori.mediana.BarreiraAcionamento11 ~ dlnorm(-12.72, 3)
```

```

p.BarreiraAcionamento11 <- 1 - exp(- lamb.BarreiraAcionamento11*T1)

for(u in 1:Z) # Determinação da verossimilhança para os especialistas
{
op.Sistema11[u] ~ dlnorm(mu.Barreira.Sistema11, tau.op.Sistema11[u])# Variabilidade dos
especialistas dada por uma lognormal
tau.op.Sistema11[u] <- 1/pow(log(ef.Sistema11[u])/1.645, 2)# Determinação de tau a partir do
fator de erro de cada especialista
}
lamb.BarreiraSistema11 ~ dlnorm(mu.Barreira.Sistema11, tau.Barreira.Sistema11)
tau.Barreira.Sistema11 <- pow(log(priori.ef.BarreiraSistema11)/1.645, -2)
priori.ef.BarreiraSistema11 ~ dlnorm(5, 5)
mu.Barreira.Sistema11 <- log(priori.mediana.BarreiraSistema11)
priori.mediana.BarreiraSistema11 ~ dlnorm(-9.69, 0.6)
p.BarreiraSistema11 <- 1 - exp(- lamb.BarreiraSistema11*T1)

p.Barreira11 <- p.BarreiraAcionamento11*erro.insp + p.BarreiraSistema11*erro.insp -
(p.BarreiraAcionamento11*erro.insp* p.BarreiraSistema11*erro.insp)

```

### **#Barreira 21 - Sistema Acústico**

#### **# Barreira 21 é a Barreira 2 no tempo T1 com portão OR**

```

for(v in 1:A) # Determinação da verossimilhança para os especialistas
{
op.Acionamento21[v] ~ dlnorm(mu.Barreira.Acionamento21, tau.op.Acionamento21[v]) #
Variabilidade dos especialistas dada por uma lognormal
tau.op.Acionamento21[v] <- 1/pow(log(ef.Acionamento21[v])/1.645, 2)# Determinação de tau a
partir do fator de erro de cada especialista
}
lamb.BarreiraAcionamento21 ~ dlnorm(mu.Barreira.Acionamento21,
tau.Barreira.Acionamento21)
tau.Barreira.Acionamento21 <- pow(log(priori.ef.BarreiraAcionamento21)/1.645, -2)
priori.ef.BarreiraAcionamento21 ~ dlnorm(5, 5)
mu.Barreira.Acionamento21 <- log(priori.mediana.BarreiraAcionamento21)
priori.mediana.BarreiraAcionamento21 ~dlnorm( -12.72, 3)
p.BarreiraAcionamento21 <- 1 - exp(- lamb.BarreiraAcionamento21*T1)

for(x in 1:B) # Determinação da verossimilhança para os especialistas
{
op.Sistema21[x] ~ dlnorm(mu.Barreira.Sistema21, tau.op.Sistema21[x]) # Variabilidade dos
especialistas dada por uma lognormal
tau.op.Sistema21[x] <- 1/pow(log(ef.Sistema21[x])/1.645, 2)# Determinação de tau a partir do
fator de erro de cada especialista
}
lamb.BarreiraSistema21 ~ dlnorm(mu.Barreira.Sistema21, tau.Barreira.Sistema21)
tau.Barreira.Sistema21 <- pow(log(priori.ef.BarreiraSistema21)/1.645, -2)
priori.ef.BarreiraSistema21 ~ dlnorm(5, 5)
mu.Barreira.Sistema21 <- log(priori.mediana.BarreiraSistema21)
priori.mediana.BarreiraSistema21 ~ dlnorm(-9.43, 0.5)
p.BarreiraSistema21 <- 1 - exp(- lamb.BarreiraSistema21*T1)

p.Barreira21 <- p.BarreiraAcionamento21*erro.insp + p.BarreiraSistema21*erro.insp -
(p.BarreiraAcionamento21*erro.insp* p.BarreiraSistema21*erro.insp)

```

### **#Árvore de Evento**

**#Para o tempo T1****# Conseq11 é a consequência 1 para o tempo T1**

$p.\text{Conseq11} <- p.\text{QuebraRiser} * (1 - p.\text{Barreira11})$   
 $p.\text{Conseq21} <- p.\text{QuebraRiser} * (p.\text{Barreira11}) * (1 - p.\text{Barreira21})$   
 $p.\text{Conseq31} <- p.\text{QuebraRiser} * (p.\text{Barreira11}) * (p.\text{Barreira21})$

**#Tempo T2****#Condiciona dos eventos básicos ao longo do tempo**

$p.\text{EventoBase1\_2} <- ((p.\text{EventoBase1}) * (1 - (p.\text{EventoBase1} * \text{erro.insp}))) + p.\text{EventoBase1} * \text{erro.insp}$

$p.\text{EventoBase2\_2} <- ((p.\text{EventoBase2}) * (1 - (p.\text{EventoBase2} * \text{erro.insp}))) + p.\text{EventoBase2} * \text{erro.insp}$

$p.\text{EventoBase3\_2} <- ((p.\text{EventoBase3}) * (1 - (p.\text{EventoBase3} * \text{erro.insp}))) + p.\text{EventoBase3} * \text{erro.insp}$

$p.\text{EventoBase4\_2} <- ((p.\text{EventoBase4}) * (1 - (p.\text{EventoBase4} * \text{erro.insp}))) + p.\text{EventoBase4} * \text{erro.insp}$

$p.\text{EventoBase6\_2} <- ((p.\text{EventoBase6}) * (1 - (p.\text{EventoBase6} * \text{erro.insp}))) + p.\text{EventoBase6} * \text{erro.insp}$

$p.\text{EventoBase7\_2} <- ((p.\text{EventoBase7}) * (1 - (p.\text{EventoBase7} * \text{erro.insp}))) + p.\text{EventoBase7} * \text{erro.insp}$

$p.\text{EventoBase8\_2} <- ((p.\text{EventoBase8}) * (1 - (p.\text{EventoBase8} * \text{erro.insp}))) + p.\text{EventoBase8} * \text{erro.insp}$

$p.\text{EventoBase9\_2} <- ((p.\text{EventoBase9}) * (1 - (p.\text{EventoBase9} * \text{erro.insp}))) + p.\text{EventoBase9} * \text{erro.insp}$

$p.\text{EventoBase10\_2} <- ((p.\text{EventoBase10}) * (1 - (p.\text{EventoBase10} * \text{erro.insp}))) + p.\text{EventoBase10} * \text{erro.insp}$

$p.\text{EventoBase11\_2} <- ((p.\text{EventoBase11}) * (1 - (p.\text{EventoBase11} * \text{erro.insp}))) + p.\text{EventoBase11} * \text{erro.insp}$

$p.\text{EventoBase12\_2} <- ((p.\text{EventoBase12}) * (1 - (p.\text{EventoBase12} * \text{erro.insp}))) + p.\text{EventoBase12} * \text{erro.insp}$

$p.\text{FalhadoCorpo\_2} <- p.\text{EventoBase10\_2} + p.\text{EventoBase11\_2} + p.\text{EventoBase12\_2} - (p.\text{EventoBase10\_2} * p.\text{EventoBase11\_2}) - (p.\text{EventoBase10\_2} * p.\text{EventoBase12\_2}) - (p.\text{EventoBase11\_2} * p.\text{EventoBase12\_2}) + (p.\text{EventoBase10\_2} * p.\text{EventoBase11\_2} * p.\text{EventoBase12\_2})$

$p.\text{FalhaIntrinseca\_2} <- p.\text{EventoBase9\_2} + p.\text{FalhadoCorpo\_2} - (p.\text{EventoBase9\_2} * p.\text{FalhadoCorpo\_2})$

$p.\text{FalhaPressurizacao\_2} <- p.\text{EventoBase2\_2} + p.\text{EventoBase3\_2} + p.\text{EventoBase4\_2} - (p.\text{EventoBase2\_2} * p.\text{EventoBase3\_2}) - (p.\text{EventoBase2\_2} * p.\text{EventoBase4\_2}) - (p.\text{EventoBase3\_2} * p.\text{EventoBase4\_2}) + (p.\text{EventoBase2\_2} * p.\text{EventoBase3\_2} * p.\text{EventoBase4\_2})$

p.EventoBase4\_2)

p.FalhaTensionadores\_2 <- p.EventoBase1\_2 + p.FalhaPressurizacao\_2 - (p.EventoBase1\_2 \* p.FalhaPressurizacao\_2)

p.PerdaPosicao\_2 <- p.EventoBase6\_2 \* p.EventoBase7\_2 \* (1-p.EventoBase8\_2) +  
p.EventoBase8\_2 \* p.EventoBase7\_2 \* (1-p.EventoBase6\_2) + p.EventoBase8\_2 \*  
p.EventoBase7\_2 \* p.EventoBase6\_2

p.QuebraRiser\_2 <- p.FalhaIntrinseca\_2 + p.FalhaTensionadores\_2 + p.PerdaPosicao\_2 - (  
p.FalhaIntrinseca\_2 \* p.FalhaTensionadores\_2) - (p.FalhaIntrinseca\_2 \* p.PerdaPosicao\_2) -  
(p.FalhaTensionadores\_2 \* p.PerdaPosicao\_2) + (p.FalhaIntrinseca\_2 \* p.PerdaPosicao\_2 \*  
p.FalhaTensionadores\_2)

### #Barreiras de Mitigação

#### #Barreira 12

p.BarreiraAcionamento12 <- ((p.BarreiraAcionamento11)\*(1-  
(p.BarreiraAcionamento11\*erro.insp)) + p.BarreiraAcionamento11\*erro.insp)\*erro.insp

p.BarreiraSistema12 <- ((p.BarreiraSistema11)\*(1-(p.BarreiraSistema11\*erro.insp)) +  
p.BarreiraSistema11\*erro.insp)\*erro.insp

p.Barreira12 <- p.BarreiraAcionamento12 + p.BarreiraSistema12 - (p.BarreiraAcionamento12 \*  
p.BarreiraSistema12)

#### #Barreira 22

p.BarreiraAcionamento22 <- ((p.BarreiraAcionamento21)\*(1-  
(p.BarreiraAcionamento21\*erro.insp)) + p.BarreiraAcionamento21\*erro.insp)\*erro.insp

p.BarreiraSistema22 <- ((p.BarreiraSistema21)\*(1-(p.BarreiraSistema21\*erro.insp)) +  
p.BarreiraSistema21\*erro.insp)\*erro.insp

p.Barreira22 <- p.BarreiraAcionamento22 + p.BarreiraSistema22 - (p.BarreiraAcionamento22 \*  
p.BarreiraSistema22)

### #Árvore de Evento

#### #Para o tempo T2

p.Conseq12 <- p.QuebraRiser\_2 \* (1 - p.Barreira12)  
p.Conseq22 <- p.QuebraRiser\_2 \* (p.Barreira12) \* (1 - p.Barreira22)  
p.Conseq32 <- p.QuebraRiser\_2 \* (p.Barreira12) \* (p.Barreira22)

### #Evento T3

#### #Condicional dos eventos básicos ao longo do tempo

x.QuebraRiser\_3 ~ dbin(p.QuebraRiser\_3, n.QuebraRiser\_3)

p.EventoBase1\_3 <- (p.EventoBase1)\*(1-p.EventoBase1\_2) + p.EventoBase1\_2

p.EventoBase2\_3 <- (p.EventoBase2)\*(1-p.EventoBase2\_2) + p.EventoBase2\_2

p.EventoBase3\_3 <- (p.EventoBase3)\*(1-p.EventoBase3\_2) + p.EventoBase3\_2

$$p.\text{EventoBase4\_3} <- (p.\text{EventoBase4}) * (1 - p.\text{EventoBase4\_2}) + p.\text{EventoBase4\_2}$$

$$p.\text{EventoBase6\_3} <- (p.\text{EventoBase6}) * (1 - p.\text{EventoBase6\_2}) + p.\text{EventoBase6\_2}$$

$$p.\text{EventoBase7\_3} <- (p.\text{EventoBase7}) * (1 - p.\text{EventoBase7\_2}) + p.\text{EventoBase7\_2}$$

$$p.\text{EventoBase8\_3} <- (p.\text{EventoBase8}) * (1 - p.\text{EventoBase8\_2}) + p.\text{EventoBase8\_2}$$

$$p.\text{EventoBase9\_3} <- (p.\text{EventoBase9}) * (1 - p.\text{EventoBase9\_2}) + p.\text{EventoBase9\_2}$$

$$p.\text{EventoBase10\_3} <- (p.\text{EventoBase10}) * (1 - p.\text{EventoBase10\_2}) + p.\text{EventoBase10\_2}$$

$$p.\text{EventoBase11\_3} <- (p.\text{EventoBase11}) * (1 - p.\text{EventoBase11\_2}) + p.\text{EventoBase11\_2}$$

$$p.\text{EventoBase12\_3} <- (p.\text{EventoBase12}) * (1 - p.\text{EventoBase12\_2}) + p.\text{EventoBase12\_2}$$

$$p.\text{FalhadoCorpo\_3} <- p.\text{EventoBase10\_3} + p.\text{EventoBase11\_3} + p.\text{EventoBase12\_3} - (p.\text{EventoBase10\_3} * p.\text{EventoBase11\_3}) - (p.\text{EventoBase10\_3} * p.\text{EventoBase12\_3}) - (p.\text{EventoBase11\_3} * p.\text{EventoBase12\_3}) + (p.\text{EventoBase10\_3} * p.\text{EventoBase11\_3} * p.\text{EventoBase12\_3})$$

$$p.\text{FalhaIntrinseca\_3} <- p.\text{EventoBase9\_3} + p.\text{FalhadoCorpo\_3} - (p.\text{EventoBase9\_3} * p.\text{FalhadoCorpo\_3})$$

$$p.\text{FalhaPressurizacao\_3} <- p.\text{EventoBase2\_3} + p.\text{EventoBase3\_3} + p.\text{EventoBase4\_3} - (p.\text{EventoBase2\_3} * p.\text{EventoBase3\_3}) - (p.\text{EventoBase2\_3} * p.\text{EventoBase4\_3}) - (p.\text{EventoBase3\_3} * p.\text{EventoBase4\_3}) + (p.\text{EventoBase2\_3} * p.\text{EventoBase3\_3} * p.\text{EventoBase4\_3})$$

$$p.\text{FalhaTensionadores\_3} <- p.\text{EventoBase1\_3} + p.\text{FalhaPressurizacao\_3} - (p.\text{EventoBase1\_3} * p.\text{FalhaPressurizacao\_3})$$

$$p.\text{PerdaPosicao\_3} <- p.\text{EventoBase6\_3} * p.\text{EventoBase7\_3} * (1 - p.\text{EventoBase8\_3}) + p.\text{EventoBase8\_3} * p.\text{EventoBase7\_3} * (1 - p.\text{EventoBase6\_3}) + p.\text{EventoBase8\_3} * p.\text{EventoBase7\_3} * p.\text{EventoBase6\_3}$$

$$p.\text{QuebraRiser\_3} <- p.\text{FalhaIntrinseca\_3} + p.\text{FalhaTensionadores\_3} + p.\text{PerdaPosicao\_3} - (p.\text{FalhaIntrinseca\_3} * p.\text{FalhaTensionadores\_3}) - (p.\text{FalhaIntrinseca\_3} * p.\text{PerdaPosicao\_3}) - (p.\text{FalhaTensionadores\_3} * p.\text{PerdaPosicao\_3}) + (p.\text{FalhaIntrinseca\_3} * p.\text{PerdaPosicao\_3} * p.\text{FalhaTensionadores\_3})$$

## #Barreiras de Mitigação

### #Barreira 13

$$x.\text{Barreira13} \sim \text{dbin}(p.\text{Barreira13}, n.\text{Barreira13})$$

$$p.\text{BarreiraAcionamento13} <- (p.\text{BarreiraAcionamento11}) * (1 - p.\text{BarreiraAcionamento12}) + p.\text{BarreiraAcionamento12}$$

$$p.\text{BarreiraSistema13} <- (p.\text{BarreiraSistema11}) * (1 - p.\text{BarreiraSistema12}) + p.\text{BarreiraSistema12}$$

$$p.\text{Barreira13} <- p.\text{BarreiraAcionamento13} + p.\text{BarreiraSistema13} - (p.\text{BarreiraAcionamento13} * p.\text{BarreiraSistema13})$$