

# Experts opinion-based Bayesian Inference for the Coverage Factor in BOP Reliability

Fernanda A. C. Duim, Pauli A. A. Garcia, Pedro L. C. Saldanha, Carlos M. C. Jacinto and Gilson B. A. Lima

**Abstract**—The blowout preventer is an important system for safety assurance in well drilling operations. Therefore, the efficient management of its reliability is an essential issue for risk prevention. In the present paper one considers a dynamic Bayesian network for reliability modeling, approaching corrective maintenance and an imperfect coverage factor, combining with a hierarchical Bayesian inference. Traditionally, the coverage factor in this kind of analysis for well safety is based on belief values. Considering that, we will approach it through a Bayesian analysis for the experts' opinion. Thus, the present paper presents a fully Bayesian approach for blowout preventer reliability analysis, combining experts' opinions in a dynamic Bayesian net modeling. In the end, is possible to compare results with and without imperfect coverage factor, and with belief values. The obtained results for a hypothetical case show the importance of considering the estimates' uncertainties in the context of reliability management of drilling operations.

**Index Terms**— Blowout Preventer Reliability, Coverage Factor, Expert's Opinion

## I. INTRODUÇÃO

O *blowout preventer* (BOP) é um equipamento eletromecânico de segurança utilizado nos processos de construção de poços de petróleo. Na Fig. 1 tem-se uma representação deste equipamento e que servirá de base para aplicação do procedimento metodológico aqui proposto.

A estrutura de sua instalação é organizada em forma de redundâncias, com o intuito de garantir uma maior confiabilidade. Esse equipamento tem a função de controlar e, em certas circunstâncias, vedar o poço, enquanto o mesmo é construído, buscando garantir a segurança para as operações. Sua principal função está associada ao controle de influxos de hidrocarbonetos e sobrepressões. Por isso, sua falha pode causar problemas como o *Blowout* [1]. O evento conhecido como *kick* é caracterizado quando há um influxo indesejado de formação (gás, óleo e água) para o interior do poço devido a alguma diferença de pressão. Isto ocorre quando o fluido de perfuração tem densidade menor que a pressão do fluido contido nos poros da rocha que está sendo perfurada e, portanto, há um influxo de fluido dos poros para dentro do poço. Esse tipo de evento deve ser controlado. Entretanto, em caso de falha no seu controle, o influxo da formação pode sair para o meio ambiente, evento esse conhecido como *blowout* [2]. O evento *blowout* é considerado de alto risco e com potencial de gerar consequências catastróficas.

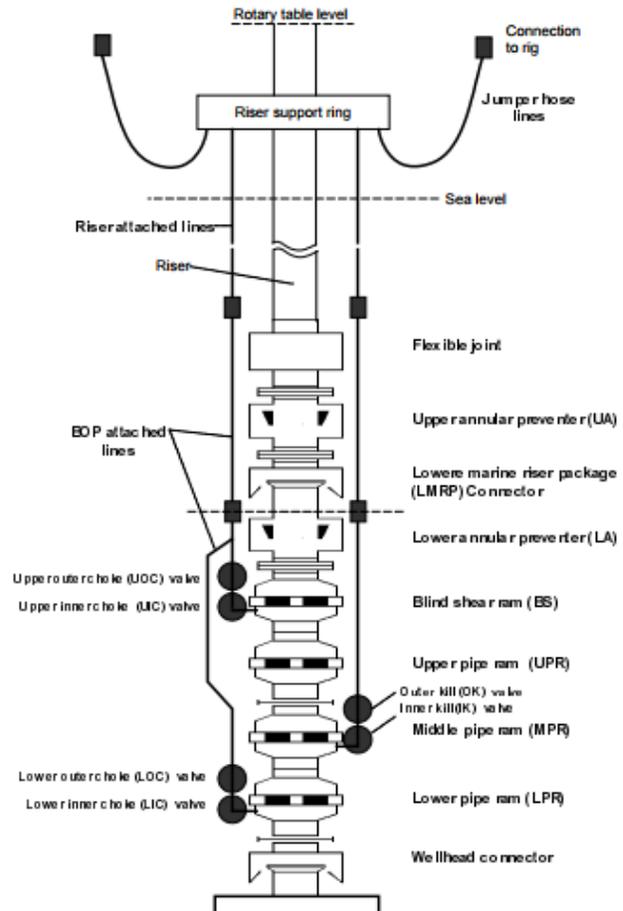


Fig. 1. Configuração típica de um BOP.  
Fonte: [3]

Exemplos disso foram os acidentes ocorridos no campo de Enchova, na Bacia de Campos, no Rio de Janeiro, em 1984, e em Macondo, no Golfo do México, em 2010.

Mesmo em sistemas com alta confiabilidade, como o caso do BOP, deve-se procurar considerar nas análises de segurança as probabilidades de falha contemplando os efeitos do envelhecimento, da possibilidade de manutenção inadequada, da chance de erro humano etc.

Essas considerações permitem avaliar o sistema com possibilidade de operar em diferentes estados, desde um funcionamento normal, passando por estados variados de degradação até a sua falha total. Quando situações como degradação e falha acontecem, a ação de manutenção é requerida para que este sistema volte a operar adequadamente. A manutenção pode ser categorizada de diferentes maneiras,

sendo as duas naturezas mais comuns às manutenções preventiva e corretiva [4]. Nesse processo, quando a intervenção é realizada, o sistema pode assumir alguns estados de funcionamento posterior. Um dos estados é o retorno do sistema/componente em condições perfeitas de funcionalidade, conhecido como reparo perfeito. Por outro lado, a intervenção pode, ocasionalmente, produzir um efeito que faça o sistema retornar para um nível de funcionamento degradado, que caracteriza um reparo imperfeito [3] e [5].

Além dessas intervenções para manutenção, o valor da confiabilidade pode sofrer modificações de acordo a capacidade das redundâncias operarem de maneira adequada. A capacidade de funcionamento adequado das redundâncias é caracterizada pelo fator de cobertura  $c$ . De acordo com estudo realizado por Dugan e Trivedi [6], o fator de cobertura é comumente aplicado em sistemas computacionais/digitais, como no caso do sistema de controle do BOP. Arnold, em [7], apresenta o conceito introduzido em sistemas reparáveis e como ele modifica a estimativa da confiabilidade.

Alguns estudos de confiabilidade no setor de óleo e gás, como [8],[9],[10] e [11], utilizaram métodos, como a Árvore de falha, Análise de efeito e modo de falha (FMEA), cadeia de Markov, redes de Petri, ou redes bayesianas para o cálculo da confiabilidade. Entretanto, com os sistemas mais toleráveis a falhas e mais seguros, e considerando-se a necessidade de serem avaliadas as dinâmicas das relações causais de falha bem como dos efeitos das intervenções no sistema, o presente trabalho irá considerar o conceito de rede bayesiana [12], [13]. Além disso, tomando por base o estudo de Dugan e Trivedi [6] e Cai et al.[12], o fator de cobertura será introduzido nos cálculos da confiabilidade. Entretanto, diferentemente de como comumente é abordado, a sua estimativa será tratada por meio de inferência bayesiana e a incerteza de sua medida, representada por sua distribuição a *posteriori*, será propagada para as estimativas da confiabilidade.

Diferentemente das contribuições trazidas pelos autores supracitados, o presente trabalho propõe um framework totalmente bayesiano contemplando o tratamento das opiniões dos especialistas por meio de um modelo bayesiano hierárquico, e propaga as incertezas destas estimativas para a estimativa final da confiabilidade do sistema, que por sua vez será modelada conforme em Cai *et al.* [12] em sua estrutura.

Sendo assim, o objetivo do presente trabalho é contemplar na modelagem da confiabilidade do sistema BOP, conforme apresentado em Cai *et al.*[12], a estimativa das opiniões dos especialistas, por meio de uma modelagem bayesiana hierárquica, e propagação das respectivas incertezas para o cálculo da confiabilidade.

## II. FUNDAMENTAÇÃO TEÓRICA

### A. Rede Bayesiana Dinâmica

Uma rede bayesiana (RB) tem por objetivo estudar as relações causais entre variáveis aleatórias, sendo a topologia representada por meio de um grafo acíclico direcionado. Essa abordagem é baseada no teorema de Bayes e tem por objetivo

representar as relações de dependências entre seus elementos e identificar as probabilidades das mesmas [14]. Uma RB é composta por um conjunto de variáveis, sendo elas discretas ou contínuas, que são representadas em forma de nós e são conectados por arcos, que representam as relações de dependência ou influência entre os mesmos [5].

As análises via RB podem ser divididas em dois segmentos, o qualitativo e quantitativo. O qualitativo auxilia na interpretação e na descrição do fenômeno por meio da rede de relacionamentos, enquanto o quantitativo busca a demonstração matemática destes. Por isso, o qualitativo é apresentado na forma de um grafo acíclico direcionado, com os nós retratando as variáveis do sistema e os arcos a dependência, ou relação causal entre os nós. Já o quantitativo é caracterizado pelas tabelas de probabilidades condicionais por apresentarem as relações probabilísticas de dependência entre os nós existentes [12].

Nas análises tradicionais via RB não são contemplados os aspectos dinâmicos do sistema investigado. Devido a isso, foi criada uma extensão dessa abordagem que permitiu que essa relação fosse possível de ser calculada ao longo do tempo, podendo contemplar as probabilidades no passado, no presente e no futuro. Esse modelo é conhecido como rede bayesiana dinâmica (RBD). Uma RBD é composta por uma sequência de intervalos de tempo (*time-slice*), onde em cada um tem-se uma rede bayesiana estática que descreve o sistema naquele intervalo de tempo específico [5]. Essa abordagem permite avaliar as probabilidades das variáveis em cada intervalo de tempo ao longo do tempo total de análise, ou seja, as probabilidades das variáveis causais em cada intervalo terão um valor e este dependerá de seu valor no intervalo anterior, criando uma relação temporal entre as variáveis causais ao longo dos intervalos de tempo. Existem duas relações possíveis entre as variáveis, elas podem ser internas ao intervalo de tempo ou externas, chamadas de *inter-slices* e *intra-slice*, respectivamente [12].

A RBD pode ser definida como um par  $(B_1, B \rightarrow)$  onde  $B_1$  representa uma rede bayesiana dinâmica que define a *a priori*  $P(X_i)$  e  $B \rightarrow$  é a probabilidade transitória  $P(X_t | X_{t-1})$  para o tempo de dois intervalos da rede bayesiana [15]. A equação que representa a probabilidade de um nó em relação um intervalo de tempo é dada por:

$$P(X_t | X_{t-1}) = \prod_{i=1}^N P(X_t^i | Pa(X_t^i)) \quad (1)$$

Em que  $X_t^i$  é o valor para o  $i$ -ésimo nó no tempo  $t$  ( $i=1,2,3,\dots,N$ ), com  $N$  sendo o número total de nós, e  $Pa(X_t^i)$  os nós pais do nó  $X_t^i$  da rede.

O resultado da distribuição de probabilidade conjunta até o tempo  $T$  pode ser dada por:

$$P(X_{1:T}) = \prod_{t=1}^T \prod_{i=1}^N P(X_t^i | Pa(X_t^i)) \quad (2)$$

O cálculo de dependência entre as variáveis, tanto na rede bayesiana estática, quanto na dinâmica, permite determinar as probabilidades de cada variável em determinado intervalo de tempo. Por isso, é fundamental identificar quais são os nós

envolvidos nas relações de dependência. Um conceito considerado nas análises aqui desenvolvidas é o de *Markov Blanket* (MB) citado no estudo [16], que fundamenta a definição dos nós de influência probabilística sobre o nó em análise na modelagem da confiabilidade do BOP. Dado uma RB, os nós podem ser classificados como nó pais, crianças e cônjuges dependendo do nó selecionado para análise. Sendo assim, dado o MB de um nó específico, os outros nós existentes na rede bayesiana serão independentes do nó específico, não influenciando no cálculo das probabilidades. Ou seja, a distribuição de probabilidade do nó escolhido é apenas dependente dos nós existentes no MB, e qualquer outra informação é redundante [17].

### B. Análise Bayesiana de Dados de Confiabilidade

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 do mesmo por meio abordagens clássicas, que presume os dados sendo independentes e igualmente distribuídos (iid). Para suprir a limitação de não se ter dados homogêneos disponíveis, e permitir a consideração de todas as informações possíveis para a estimativa de parâmetros de interesse, os conceitos da inferência Bayesiana têm se tornado cada vez mais abundantes em estudos de confiabilidade. Essa teoria é capaz de incorporar informações não empíricas para a estimativa de interesse [18]. Esta abordagem permite a consideração de vários tipos de informações, como a opiniões de especialistas, dados de campo específicos e dados de campo oriundos de sistemas similares, em um mesmo processo de estimação [19].

Na abordagem bayesiana os dados são caracterizados como observações coletadas no processo de estudo, estando eles sujeitos a incertezas, que podem estar associadas a erros de mensuração, de interpretação, entre outros que podem ocorrer durante o levantamento dos mesmos. A partir de uma organização dos dados, manipulação ou análise dos mesmos são geradas informações. Essas têm por objetivo agregar conhecimentos sobre o componente ou sistema de interesse. A inferência é descrita como o processo de obter uma conclusão dado esse conhecimento existente [19]. A inferência é embasada no teorema de Bayes, representado pela equação 3:

$$\pi_1(\theta|x) = \frac{f(x|\theta)\pi_0(\theta)}{\int f(x|\theta)\pi_0(\theta)d\theta} \quad (3)$$

Na equação (3), o parâmetro de interesse desconhecido é o  $\theta$ , podendo ele ser um vetor,  $\pi_0(\theta)$  é a distribuição *a priori* de  $\theta$ ,  $f(x|\theta)$  é a função de verossimilhança e  $\pi_1(\theta|x)$  a distribuição *a posteriori* de  $\theta$ , dado um vetor aleatório  $x$  de informações. Para esse cálculo é preciso ter conhecimento da distribuição *a priori* do parâmetro de interesse. Entretanto em alguns casos, os sistemas analisados possuem uma carência de dados que dificultam a obtenção dessa distribuição.

Devido à escassez de dados do parâmetro de interesse, a estimativa do mesmo pode ser tratada por uma variedade de

fontes de dados como, por exemplo, a opinião de especialistas [20]. Para esse tratamento se utilizará o conceito de análise hierárquica ou modelo bayesiano hierárquico. Ele se caracteriza por utilizar múltiplos estados de distribuições *a priori*, ou distribuições *a priori* hierarquizadas. Ou seja, a distribuição *a priori* de um parâmetro pode depende de outros parâmetros, e estes são representados por outras distribuições *a priori*, denominadas de *hiperprioris*. Nessas condições, a distribuição *a priori* para o parâmetro de interesse -  $\pi(\theta)$ - é dado por:

$$\pi(\theta) = \int \pi_1(\theta|\varphi)\pi_2(\varphi)d\varphi \quad (4)$$

De acordo com a equação (4),  $\pi_1(\theta|\varphi)$  é a distribuição *a priori* de primeiro nível, que representa a variabilidade populacional de  $\theta$  para um dado vetor  $\varphi$  de parâmetros. A distribuição que representa as incertezas acerca  $\theta$  (que pode ser um vetor) é dada por  $\pi_2(\varphi)$ , também conhecida como *hiperpriori*. Quando  $\varphi$  for representado por um vetor, cujas componentes são denominadas de hiperparâmetros. Utilizando as variabilidades da distribuição *a priori* e da *hiperprioris* para estimar o parâmetro de interesse, ele pode ser obtido na forma de uma taxa global média [19].

Em um processo de análise de variabilidade populacional, assume-se que a distribuição pode ser descrita por um membro de uma dada família de modelos de distribuição de parâmetros. Sendo o modelo de distribuição da variabilidade do parâmetro dado por:  $\varphi(x) = \varphi(x | \gamma_1, \gamma_2, \dots, \gamma_r)$  e a distribuição de probabilidade sobre os parâmetros do modelo que descreve a incerteza sobre essa distribuição da variabilidade populacional dada por  $\pi(\gamma_1, \gamma_2, \dots, \gamma_r)$  [21].

As distribuições *a priori* de primeiro nível assumem modelos paramétricos de formato particular. Ele é determinado por assumir uma distribuição Gama ou Lognormal quando o parâmetro de interesse  $\theta$  possuir valores positivos,  $\theta > 0$ . Entretanto, quando  $-\infty < \theta < \infty$  a distribuição comumente utilizada é a Normal [19]. Para a variabilidade de  $\varphi$  é frequente utilizar modelos difusos e independentes [22].

A variabilidade populacional de  $\theta$  pode ser baseada em alguns tipos de fontes de informações, são elas, segundo [21]:

(E1) O analista com o estado de conhecimento sobre a distribuição *a priori*, neles 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, como o banco de dados de confiabilidade e julgamento de especialistas.

Para a opinião de especialistas, comumente elicitase a opinião mais provável e associa-se um fator de erro a esta estimativa. O fator de erro 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 [20-24].

### III. PROCEDIMENTO METODOLÓGICO

Conforme mencionado na introdução, o presente trabalho propõe uma abordagem metodológica que combina o uso de redes bayesianas dinâmicas com uma modelagem bayesiana hierárquica. As redes bayesianas dinâmicas são consideradas para tratar a evolução dos estados do sistema no tempo. A modelagem bayesiana hierárquica, conforme em Droguett *et al.* [21], se propõe a tratar as opiniões dos especialistas para a estimativa do fator de cobertura.

A evolução no tempo das tabelas de probabilidades condicionais será abordada por meio de uma análise markoviana, conforme em Cai *et al.* [23] e em Wang *et al.* [10].

O procedimento metodológico da proposta está subdividido em oito etapas: (1) Definição do sistema, (2) Modelagem da confiabilidade via rede bayesiana (RB) – conforme em [24] e [25], (3) Identificação das relações dinâmicas da RB em sucessivos  $\Delta t$  – Conforme em [12], atentando para as relações causais entre os intervalos de tempo, (4) Modelagem markoviana da evolução temporal entre sucessivos  $\Delta t$  – Conforme em Cai *et al.* [12] e Wang *et al.* [10], (5) Definição das tabelas de probabilidades condicionais considerando o fator de cobertura  $c$  – conforme em Cai *et al.* [12] e Wang *et al.* [10], (6) Elicitação dos especialistas sobre  $c$ , (7) Estimativa de  $c$  por meio de um modelo bayesiano hierárquico (MBH) considerando-se as fontes E1 e E3, conforme descrito na seção em B da fundamentação teórica – Conforme em [20-23], (8) Propagação das incertezas da estimativa de  $c$  para o cálculo da confiabilidade nos diferentes  $\Delta t$  ( $R_{\Delta t}$ ) – Similar a [26].

As etapas de (7) e (8) são implementadas no WinBugs [27].

Sendo assim, como resultado da etapa (8) do procedimento, ter-se-á uma distribuição para cada  $R_{\Delta t}$ . Como se deseja uma confiança de 97,5%, será observado o percentil de 2,5% das distribuições de  $R_{\Delta t}$ .

### IV. ESTUDO DE CASO

O BOP considerado no presente estudo é constituído de gaveta cega cisalhante (*blind shear ram*), gavetas de tubos superior, intermediária e inferior (*pipe ram*), anulares e conectores, ou seja, uma simplificação do que está apresentado na Fig. 1. O bom funcionamento desses componentes é fundamental para a boa operabilidade do BOP. Este artigo, conforme já mencionado, tem por objetivo apresentar um procedimento metodológico em que são contempladas e propagadas as incertezas associadas às opiniões dos especialistas quanto ao fator de cobertura  $c$ . O caso hipotético visa apresentar os resultados para a estimativa da probabilidade da ocorrência do *Blowout* a partir dos eventos causadores do mesmo. Para simplificação, apenas a tubulação inferior do BOP é considerada nesse trabalho. A modelagem considera a possibilidade de se ter um reparo imperfeito após a identificação de uma falha. A composição dos eventos, a estruturação dos sub-sistemas em série e paralelo e os dados do estudo que serão utilizados estão contidos parcialmente no trabalho de Cai *et al.* [12]. Os dados são as taxas de falha, taxas de reparo e as probabilidades dos

estados de degradação de cada componente, sendo essas probabilidades calculadas com base na etapa (4) do procedimento metodológico.

Os eventos causais, que constituem o *Markov Blanket* do evento “*Blowout*” são os *Blowout* submarino (*Subblow*) e Falha local da gaveta inferior ou associado ao equipamento do sistema de controle (LFRPCSE). O nó LFRPCSE possui nós pais que influenciam na distribuição de probabilidade. Esses nós são “Falha na função ativa do pod amarelo, azul e no sistema acústico” (BBPYPF), “Falha local da gaveta inferior” (LFLRP), e “Falha no sistema de controle” (CSO). O LFLRP também possui nós pais que são: “Vazamento no preventor interno, ou falha ao fechar” (LRPIL), “Falha hidráulica no preventor interno causada por falha no fechamento” (PIHF), e “Vazamento externo na válvula ou linha de transporte do preventor” (SVLPLE). A estrutura da rede bayesiana que modela, de maneira estática, essas relações causais podem ser vistas como sendo aquela associada a algum dos subintervalos apresentados na Fig. 2.

Para a modelagem do caso, será considerado um tempo de missão de 105 dias, que é o tempo médio que se leva para a construção de um poço [29]. Esse tempo será subdividido em 5 subintervalos de 21 dias, conforme [28]. Esse intervalo refere-se ao tempo entre testes das funcionalidades do BOP.

Na Fig. 2 pode-se observar a modelagem via rede bayesiana dinâmica. Note que o evento “*Blowout*” possui dois nós pais, o *Subblow* e LFRPCSE, e seus valores são calculados a partir de eventos básicos anteriores considerando-se a lógica envolvida em seu relacionamento causal. Como explicado anteriormente, apenas os nós que pertencem ao MB estão sendo considerados como influenciadores diretos para a distribuição de probabilidade do nó de interesse. Por esse motivo o fator de  $c$  apenas será introduzido na confiabilidade do evento principal por meio desses dois nós pais, como apresentado na Tabela I. Esse fator será estimado pela opinião de cinco especialistas na área de segurança de poço. As suas respectivas opiniões e o fator de erro associado aos mesmos podem ser vistos na Tabela II.

TABELA I  
TABELA DE PROBABILIDADE CONDICIONAL PARA OS EVENTOS EM PARALELO DE MARKOV BLANKET

<i>Subblow</i>		LFRPCSE		<i>Blowout</i>	
NO <sup>1</sup>	YES <sup>2</sup>	NO <sup>1</sup>	YES <sup>2</sup>	NO <sup>1</sup>	YES <sup>2</sup>
1	0	1	0	1	0
1	0	0	1	c	(1-c)
0	1	1	0	c	(1-c)
0	1	0	1	0	0

1 NO significa sem falha (*no failure*), 2 YES significa falha (*yes failure*)

TABELA II  
OPINIÃO DE ESPECIALISTAS PARA O FATOR DE COBERTURA

Especialista	Estimativa do fator de cobertura	Fator de Erro
1	0,90	2
2	0,95	2
3	0,925	2
4	0,97	2
5	0,90	2

Como estão sendo considerados cinco intervalos de tempo, cada um com vinte e um dias, as probabilidades dos estados são obtidas por meio da análise markoviana descrita nos procedimentos metodológicos [10 e 12]. A Tabela III apresenta os resultados dessas probabilidades dependentes do tempo t.

TABELA III  
EQUAÇÃO DAS RELAÇÕES DE TRANSIÇÃO ENTRE NÓS  
CONSECUTIVOS COM REPARO IMPERFEITO

t/t+Δt	No	DS1	DS2	Yes
No	$e^{-\lambda\Delta t}$	$0.3(1 - e^{-\lambda\Delta t})$	$0.6(1 - e^{-\lambda\Delta t})$	$0.1(1 - e^{-\lambda\Delta t})$
DS1	0	$e^{-0.9\lambda\Delta t}$	$(1 - e^{-0.9\lambda\Delta t})/3$	$2(1 - e^{-0.9\lambda\Delta t})/3$
DS2	0	0	$e^{-0.3\lambda\Delta t}$	$1 - e^{-0.3\lambda\Delta t}$
Yes	$0.7(1 - e^{-\mu\Delta t})$	$0.2(1 - e^{-\mu\Delta t})$	$0.1(1 - e^{-\mu\Delta t})$	$e^{-\mu\Delta t}$

Com a finalidade de se observar a sensibilidade da confiabilidade para com o fator de cobertura c serão analisadas três situações: (i) serão realizados os cálculos da confiabilidade do BOP considerando-se uma cobertura perfeita, ou seja, que as redundância funcionarão adequadamente sempre (c = 1); (ii) será utilizada a estimativa para o fator de cobertura c a partir do julgamento de especialistas, conforme Tabela II, considerando-se a sua destruição a posteriori obtida via MBH; (iii) será considerado o fator de cobertura fixo igual a 0.95. Esses resultados serão analisados de modo a mostrar a importância da abordagem proposta para a tomada de decisão. Os valores para cada intervalo de tempo foram obtidos pela dinâmica da rede a partir do segundo intervalo. Eles estão apresentados no Anexo I junto ao código.

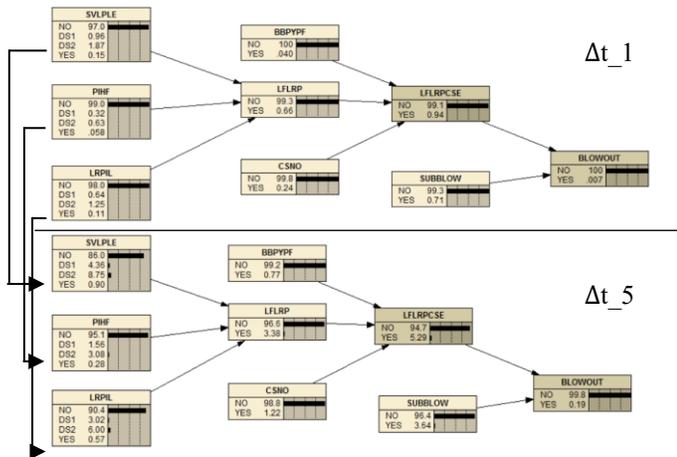


Fig. 2. Redes bayesianas para o primeiro e o quinto intervalos de teste.

V. RESULTADOS OBTIDOS

Na primeira situação descrita o valor encontrado para a confiabilidade do BOP ao término do quinto intervalo de tempo é de 99.807%. Ou seja, esse resultado reflete o funcionamento perfeito das coberturas das redundâncias quando necessário.

Na segunda situação de análise, considerando-se a estimativa do fator de cobertura a partir da opinião de especialistas (Tabela II), o resultado encontrado para a confiabilidade, admitindo-se uma confiança de 97,5%, ou seja, para o percentil de 2,5%, no quinto intervalo de tempo, tem-se um limite inferior para a confiabilidade de 96,37%. Ou seja, isso significa que com 97,5% de confiança, com base nas estimativas dos especialistas para o fator de cobertura, a confiabilidade do BOP no quinto intervalo de tempo é de, pelo menos, 96,37%. Note que esse intervalo contempla a estimativa obtida ao se considerar uma cobertura perfeita, ou seja, c = 1. Na Fig. 3 têm-se as variabilidades populacionais estimadas para o fator de cobertura c, que foi propagada para a estimativa da confiabilidade no final desse período de cinco intervalos, Fig. 4. Os resultados alcançados nesse caso, que reflete a proposta metodológica do presente artigo, foram alcançados com o código em WinBugs, cuja apresentação parcial referente ao primeiro subintervalo encontra-se no Anexo I.

No terceiro caso de análise, assumindo-se que o fator de cobertura c seja igual a 0,95, segundo os especialistas, e considerando-se ainda que essa é uma estimativa pontual e sem quaisquer incertezas associadas às mesmas, a estimativa da confiabilidade do BOP para o último intervalo de tempo é de 99,379%.

Constata-se com isso que, para o presente caso, com a estimativa do fator de cobertura a partir do julgamento de especialistas, e considerando-se um intervalo de confiança de 97,5%, a estimativa da confiabilidade é de no mínimo de 96,37% no final dos cinco intervalos de testes. Isso representa uma estimativa mais conservadora para a confiabilidade, cujo intervalo de confiança contempla as estimativas geradas pelos outros dois casos. Isso dá maior flexibilidade enriquecendo as informações para o processo decisório.

Como abordado anteriormente, muitos trabalhos utilizam o fator de c com uma medida fixa de 0,95 sem justificar o motivo como em [1] e [12]. Como é apresentada nos resultados gerados pelo caso, ao considerar essa medida alta para o parâmetro, a confiabilidade aumenta para 99,379% quando comparada ao mínimo de 96,37%, obtido considerando-se as incertezas associadas às opiniões. Isto é, a incerteza ligada ao julgamento de especialistas possui uma influência no resultado da probabilidade de ocorrência de falha de um evento de interesse, que nesse caso é o BOP.

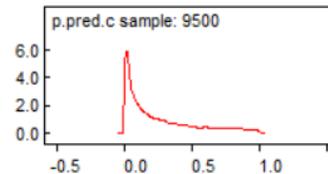


Fig. 3. Variabilidade populacional estimada para o fator de cobertura

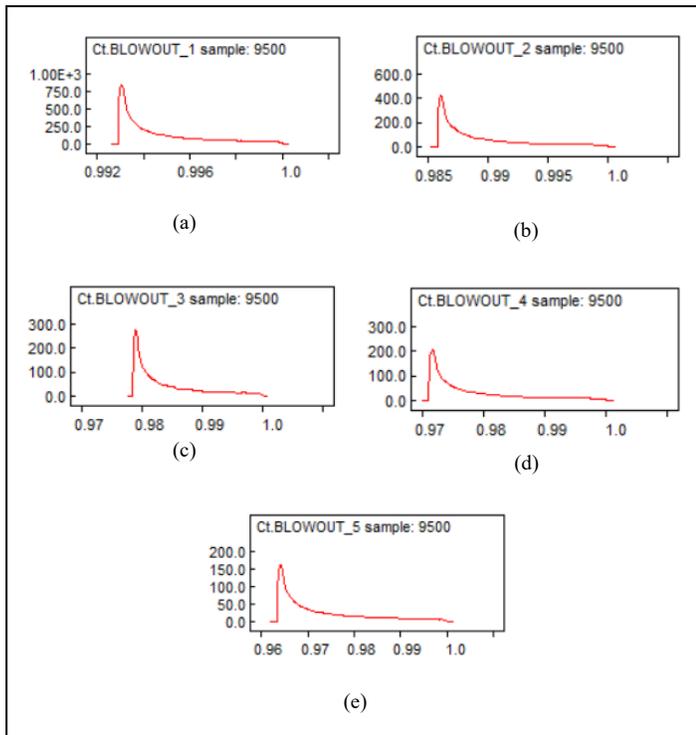


Fig. 4. Variabilidades populacionais para os intervalos  $\Delta t$  de 1 a 5, respectivamente

Na Tabela IV têm-se as estimativas para a confiabilidade em cada um dos cinco subintervalos.

TABELA IV  
ESTIMATIVAS PARA A CONFIABILIDADE EM CADA  
SUBINTERVALO DA RBD

Confiabilidade	$\mu^{(1)}$	Sd <sup>(2)</sup>	$P_{2,5\%}^{(3)}$	$P_{50\%}^{(4)}$
$\Delta t_1$	0,9947	0,001862	0,9930	0,9939
$\Delta t_2$	0,9893	0,003738	0,9859	0,9878
$\Delta t_3$	0,9838	0,005664	0,9786	0,9815
$\Delta t_4$	0,9782	0,007627	0,9712	0,9750
$\Delta t_5$	0,9725	0,009617	0,9637	0,9685

(1), (2), (3) e (4) representam, respectivamente, as estimativas da média, do desvio padrão e dos percentis de 2,5% e 50%;

## VI. CONCLUSÕES

O presente trabalho teve por objetivo apresentar uma abordagem baseada em rede bayesiana dinâmica combinada com tratamento bayesiano da opinião de especialistas sobre o fator de cobertura para a estimativa da confiabilidade de BOP. Os resultados obtidos mostram, mesmo que por meio de um estudo de caso simplificado, que a riqueza de informações trazidas pela abordagem permite que o tomador de decisões tenha mais subsídios para apoiá-lo nesse processo.

A consideração das incertezas associadas à opinião de especialistas para estimar o fator de cobertura, e sua propagação para o cálculo da confiabilidade, é uma proposta que proporciona resultados práticos de interesse para a indústria, tendo em vista as dificuldades em se ter abundância de dados para um tratamento clássico dos mesmos.

Para trabalhos futuros propõe-se a consideração de informações de alto nível, como o histórico de ocorrências de

*blowout* em determinado cenário, para atualizar as estimativas iniciais do fator de cobertura e de outros parâmetros de confiabilidade, como taxas de falha e/ou probabilidades de falha na demanda.

## APÊNDICE

### CÓDIGO EM WINBUGS

```
Model{
#Estimativa do fator de cobertura
for ( i in 1: N)
{
op.c[i] ~ dlnorm (mu.c, tau.op.c[i])I(0,1) #Variabilidade dos especialistas
para o fator c
tau.op.c[i] <- 1/pow(log(ef.c [i]) /1.645, 2) #Parâmetro de acordo com o
fator de erro
}
p.pred.c ~ dlnorm (mu.c, tau.c)I(0,1) #Preditiva do fator de cobertura c
mu.c <- log(priori.mediana.c) # Parametros do fator de cobertura
tau.c <- 1/pow(log(priori.ef.c) /1.654, 2)
priori.ef.c ~ dlnorm (5,5) # Hiperprioris para o fator de erro
priori.mediana.c ~ dlnorm (0.87, 10)I(0,1)
}
```

```
#1 Intervalo
#O subsistema SUBBLOW
Ct.SUBBLOW_1 <- 1 - Ft.SUBBLOW_1
```

```
#O subsistema CSNO
Ct.CSNO_1 <- 1 - Ft.CSNO_1
```

```
# O subsistema BBPYPF
Ct.BBPYPF_1 <- 1 - Ft.BBPYPF_1
```

```
#Encontrados todos os subsistemas da árvore principal é iniciado a operação
para o cálculo do sistema de BLOWOUT.
#O subsistema LFLRPCSE é formado pelos subsistemas BBPYPF, LFLRP e
CSNO
```

```
ProbYesYesYes_LFLRPCSE_1 <- Ft.BBPYPF_1* Ft.LFLRP_1*Ft.CSNO_1
```

```
F32_1 <- ProbYesYesYes_LFLRPCSE_1
```

```
Ft.LFLRPCSE_1 <- F32_1
```

```
Ct.LFLRPCSE_1 <- 1-Ft.LFLRPCSE_1
```

```
#Sistema BLOWOUT a partir dos subsistemas SUBBLOW e LFLRPCSE que
se encontram em paralelo
```

```
ProbNoNo_BLOWOUT_1 <- Ct.SUBBLOW_1 * Ct.LFLRPCSE_1
ProbNoYes_BLOWOUT_1 <- Ct.SUBBLOW_1 * Ft.LFLRPCSE_1
ProbYesNo_BLOWOUT_1 <- Ft.SUBBLOW_1 *Ct.LFLRPCSE_1
ProbYesYes_BLOWOUT_1 <- Ft.SUBBLOW_1* Ft.LFLRPCSE_1
```

```
F33_1 <- ProbNoNo_BLOWOUT_1*0
F34_1 <-ProbNoYes_BLOWOUT_1*(1- p.pred.c)
F35_1 <- ProbYesNo_BLOWOUT_1*(1- p.pred.c)
F36_1 <- ProbYesYes_BLOWOUT_1*1
```

```
Ft.BLOWOUT_1 <- F33_1+F34_1+F35_1+F36_1
Ct.BLOWOUT_1 <- 1-Ft.BLOWOUT_1
```

```
}
Data
list(
N=5,
op.c = c(0.90,0.95,0.925,0.97, 0.90),
ef.c = c(2,2,2,2,2),
Ft.SUBBLOW_1 = 0.00704
Ft.CSNO_1 =0.00235
Ft.BBPYPF_1 =0.00031
```

Ft.LFLRP\_1 = 0.006723  
 Ft.SUBBLOW\_2 = 0.01413  
 Ft.CSNO\_2 = 0.00474  
 Ft.BBPYPF\_2 = 0.00122  
 Ft.LFLRP\_2 = 0.01347  
 Ft.SUBBLOW\_3 = 0.02141  
 Ft.CSNO\_3 = 0.00717  
 Ft.BBPYPF\_3 = 0.00276  
 Ft.LFLRP\_3 = 0.02025  
 Ft.SUBBLOW\_4 = 0.02883  
 Ft.CSNO\_4 = 0.00966  
 Ft.BBPYPF\_4 = 0.00490  
 Ft.LFLRP\_4 = 0.02706  
 Ft.SUBBLOW\_5 = 0.03635  
 Ft.CSNO\_5 = 0.01220  
 Ft.BBPYPF\_5 = 0.00765  
 Ft.LFLRP\_5 = 0.03389

#### AGRADECIMENTOS

Os autores agradecem: (i) a fundação Capes pelo oferecimento dos artigos que foram fundamentais para a realização desse trabalho, (ii) aos revisores anônimos que nos brindaram com observações importantes para a melhoria deste trabalho, (iii) a Petrobras pelo suporte financeiro vinculado ao projeto TC 5850.0102426.16.9.

#### REFERÊNCIAS

- [1] Z. Liu, Y. Liu, B. Cai, D. Zhang, and C. Zheng, "Dynamic Bayesian network modeling of reliability of subsea blowout preventer stack in presence of common cause failures," *J. Loss Prev. Process Ind.*, vol. 38, pp. 58–66, 2015, doi: 10.1016/j.jlp.2015.09.001.
- [2] Q. Onda and C. Pregão, "Relatório de segurança operacional das atividades de exploração e produção de petróleo e gás natural ANP," 2013.
- [3] P. Holand, "Reliability of subsea bop systems for deepwater application, phase ii dw unrestricted version," *SINTEF Ind. Manag. Trondheim, Norw.*, 1999.
- [4] M. Tanwar, R. N. Rai, and N. Bolia, "Imperfect repair modeling using Kijima type generalized renewal process," *Reliab. Eng. Syst. Saf.*, vol. 124, pp. 24–31, 2014, doi: 10.1016/j.res.2013.10.007.
- [5] P. A. P. Ramirez and I. B. Utne, "Use of dynamic Bayesian networks for life extension assessment of ageing systems," *Reliab. Eng. Syst. Saf.*, vol. 133, pp. 119–136, 2015, doi: 10.1016/j.res.2014.09.002.
- [6] J. B. Dugan and K. S. Trivedi, "Coverage Modeling for Dependability Analysis of Faulttolerant Systems," *IEEE Trans. Comput.*, vol. 38, no. 6, pp. 775–787, 1989, doi: 10.1109/12.24286.
- [7] T. F. Arnold, "The Concept of Coverage and Its Effect on the Reliability Model of a Repairable System," *IEEE Trans. Comput.*, vol. C-22, no. 3, pp. 251–254, 1973, doi: 10.1109/T-C.1973.223703.
- [8] M. Shafiee, E. Enjema, and A. Kolios, "An integrated FTA-FMEA model for risk analysis of engineering systems: A case study of subsea blowout preventers," *Appl. Sci.*, vol. 9, no. 6, 2019, doi: 10.3390/app9061192.
- [9] L. Ciani, G. Guidi, and G. Patrizi, "Condition-based Maintenance for OilGas system basing on Failure Modes and Effects Analysis," *5th Int. Forum Res. Technol. Soc. Ind. Innov. to Shape Futur. RTSI 2019 - Proc.*, pp. 85–90, 2019, doi: 10.1109/RTSI.2019.8895587.
- [10] C. Wang, Y. Liu, W. Hou, G. Wang, and Y. Zheng, "Reliability and availability modeling of Subsea Xmas tree system using Dynamic Bayesian network with different maintenance methods," *J. Loss Prev. Process Ind.*, vol. 64, no. February, p. 104066, 2020, doi: 10.1016/j.jlp.2020.104066.
- [11] J. Andrews and C. Fecarotti, "System design and maintenance modelling for safety in extended life operation," *Reliab. Eng. Syst. Saf.*, vol. 163, no. February, pp. 95–108, 2017, doi: 10.1016/j.res.2017.01.024.
- [12] B. Cai, Y. Liu, Y. Zhang, Q. Fan, and S. Yu, "Dynamic Bayesian networks based performance evaluation of subsea blowout preventers in presence of imperfect repair," *Expert Syst. Appl.*, vol. 40, no. 18, pp. 7544–7554, 2013, doi: 10.1016/j.eswa.2013.07.064.
- [13] N. Khakzad, F. Khan, and P. Amyotte, "Risk-based design of process systems using discrete-time Bayesian networks," *Reliab. Eng. Syst. Saf.*, vol. 109, pp. 5–17, 2013, doi: 10.1016/j.res.2012.07.009.
- [14] S. Barua, X. Gao, H. Pasman, and M. S. Mannan, "Bayesian network based dynamic operational risk assessment," *J. Loss Prev. Process Ind.*, vol. 41, no. 2016, pp. 399–410, 2016, doi: 10.1016/j.jlp.2015.11.024.
- [15] K. P. Murphy, "Dynamic Bayesian Networks: Representation, Inference and Learning, dissertation," *PhD thesis, UC Berkley, Dept. Comp. Sci.*, 2002.
- [16] S. Fu and M. C. Desmarais, "Tradeoff analysis of different Markov blanket local learning approaches," in *Pacific-Asia Conference on Knowledge Discovery and Data Mining*, 2008, pp. 562–571.
- [17] T. Gao and Q. Ji, "Hybrid Markov Blanket discovery," in *2016 23rd International Conference on Pattern Recognition (ICPR)*, 2016, pp. 1653–1658.
- [18] D. Kelly and C. Smith, *Bayesian Inference for Probabilistic Risk Assessment*. 2011.
- [19] D. L. Kelly and C. L. Smith, "Bayesian inference in probabilistic risk assessment--The current state of the art," *Reliab. Eng. Syst. Saf.*, vol. 94, no. 2, pp. 628–643, 2009, doi: 10.1016/j.res.2008.07.002.
- [20] D. L. Kelly and N. O. Siu, "Bayesian parameter estimation in probabilistic risk assessment," *Reliab. Eng. Syst. Saf.*, vol. 62, no. 1–2, pp. 89–116, 1998, [Online]. Available: [http://linkinghub.elsevier.com/retrieve/pii/S0951832097001592%0Afile:///Files/FF/FF7C4817-BAB3-4130-8336-184AF17F2B23.pdf%0Apapers3://publication/doi/10.1016/S0951-8320\(97\)00159-2](http://linkinghub.elsevier.com/retrieve/pii/S0951832097001592%0Afile:///Files/FF/FF7C4817-BAB3-4130-8336-184AF17F2B23.pdf%0Apapers3://publication/doi/10.1016/S0951-8320(97)00159-2).
- [21] E. L. Drogue, F. Groen, and A. Mosleh, "The combined use of data and expert estimates in population variability analysis," *Reliab. Eng. Syst. Saf.*, vol. 83, no. 3, pp. 311–321, 2004.
- [22] D. L. Kelly and C. L. Atwood, "Bayesian Modeling of Population Variability--Practical Guidance and Pitfalls," Idaho National Laboratory (INL), 2008.
- [23] B. Cai *et al.*, "Performance evaluation of subsea BOP control systems using dynamic Bayesian networks with imperfect repair and preventive maintenance," *Eng. Appl. Artif. Intell.*, vol. 26, no. 10, pp. 2661–2672, 2013.
- [24] A. Bobbio, L. Portinale, M. Minichino, and E. Ciancamerla, "Improving the analysis of dependable systems by mapping fault trees into Bayesian networks," *Reliab. Eng. Syst. Saf.*, vol. 71, no. 3, pp. 249–260, 2001.
- [25] B. Cai *et al.*, "Application of Bayesian networks in reliability evaluation," *IEEE Trans. Ind. Informatics*, vol. 15, no. 4, pp. 2146–2157, 2018.
- [26] H. Yu, F. Khan, and B. Veitch, "A flexible hierarchical Bayesian modeling technique for risk analysis of major accidents," *Risk Anal.*, vol. 37, no. 9, pp. 1668–1682, 2017.
- [27] D. J. Lunn, A. Thomas, N. Best, and D. Spiegelhalter, "WinBUGS-a Bayesian modelling framework: concepts, structure, and extensibility," *Stat. Comput.*, vol. 10, no. 4, pp. 325–337, 2000.
- [28] A. P. I. Sid, "53, Blowout Prevention Equipment Systems for Drilling Wells. 2016," *Washington, DC API*.
- [29] Relatório Petrobrás Fatos e Dados. "Completamos 10 anos de produção no pré-sal". 2018, Rio de Janeiro, Brasil. Available: <https://www.petrobras.com.br/fatos-e-dados/completamos-dez-anos-de-producao-no-pre-sal.htm#:~:text=A%20m%C3%A9dia%20de%20tempo%20utilizado,p%C3%A7%C3%A7%C3%AAs%20vezes%20mais%20r%C3%A1pida>.



**Fernanda Abizethe de Carvalho Duim**  
 Doutoranda no programa de Sistema de Gestão Sustentável da Universidade Federal Fluminense. Mestre em Engenharia de Produção da Universidade Federal Fluminense na área de Confiabilidade. Graduada em Engenharia de produção na Universidade Federal Fluminense. Trabalhou como estagiária de

engenharia de produção na empresa Ampla Energia e Serviços, na área de Faturamento Massivo. Trabalha como professora substituta da Universidade Federal Fluminense no departamento de Engenharia de produção. Trabalha como professora da Faculdade Lusófona no departamento de logística e administração. Tem experiência na área de Engenharia de Produção, com artigos publicados nos seguintes temas: Confiabilidade, ensino de engenharia de produção, variáveis econômicas, falhas, andragogia, PMBOK, correlação. Foi aluna de Iniciação Científica na Universidade Federal Fluminense.



**Pauli Adriano de Almada Garcia** Graduado em Matemática pela Universidade Federal Fluminense (1999), Mestre em Sistemas e Computação, na área de otimização de processos, pelo Instituto Militar de Engenharia (2001) e Doutor em Engenharia Nuclear, na área de Análise Probabilística de Segurança (APS), pela Coordenação dos Programas

de Pós-Graduação de Engenharia (COPPE) da Universidade Federal do Rio de Janeiro (2006). Atualmente é Professor Associado do Departamento de Administração e Administração Pública da Universidade Federal Fluminense, lotado em Volta Redonda, onde coordena o curso de graduação em Administração e o grupo de pesquisa ARCADE - Análise de Risco, Confiabilidade e Apoio à Decisão. Atua como colaborador/pesquisador do Grupo LOGIS - Logística Integrada de Sistemas - junto ao Programa de Engenharia de Produção da Escola de Engenharia da UFF/Niterói, onde também atua em orientação de mestrado e doutorado. Tem experiência em análise de confiabilidade de sistemas, análise probabilística de riscos e apoio à decisão sob incertezas.



**Pedro Luiz da Cruz Saldanha** Possui graduação em Engenharia Elétrica pela Universidade do Estado do Rio de Janeiro (1976), mestrado em Engenharia Nuclear pela UFRJ (1995) e doutorado em Engenharia Nuclear pela Universidade Federal do Rio de Janeiro (2003). Atualmente é professor do Centro Universitário de Barra Mansa e

tecnologista sênior da Comissão Nacional de Energia Nuclear. Tem experiência na área de Engenharia Nuclear, com ênfase em Sistemas de Potência Elétrica de Usinas Nucleares, atuando principalmente nos seguintes temas: aval. segurança de sistemas de centrais nucleares, sistema de potência elétrica interno, avaliação da operação e testes periódicos, sistema de potência elétrica e licenciamento de instalações nucleares.



**Carlos Magno Couto Jacinto First A. Author** Eletrotécnico pelo CEFET-Campos, Graduado em Economia pela Universidade Federal Fluminense, Mestre em Engenharia de Produção, na área de

Métodos Quantitativos, pela Universidade Federal Fluminense e Doutor em Engenharia Civil, na área de Sistemas Computacionais, pela Coordenação dos Programas de Pós-Graduação de Engenharia (COPPE) da Universidade Federal do Rio de Janeiro. Membro da SRA - Society of Risk Analysis e da SPE - Society of Petroleum Engineers. Atualmente é Professor da Universidade Petrobras na Escola de Ciências e Tecnologia de Exploração e produção, coordenador do grupo de pesquisa em Engenharia da Confiabilidade e Análise de Risco na área de Engenharia de Poços do CENPES - Centro de Pesquisas e Desenvolvimento da Petrobras. Atua como colaborador/pesquisador do grupo de pesquisa CEERMA - Centro de Estudos e Ensaio em Risco e Modelagem Ambiental da UFPE e do grupo de pesquisa ARCADE - Análise de Risco, Confiabilidade e Apoio à Decisão da UFF. Tem experiência em Modelagem, Simulação e Otimização de Sistemas, atuando principalmente em Análise de Risco e Engenharia de Confiabilidade na Área de Petróleo e Gás.



**Gilson Brito Alves Lima** Engenheiro Civil, Especialista em Engenharia de Segurança pela Universidade Federal Fluminense. Mestre em Engenharia Civil pela Universidade Federal Fluminense e Doutor em Engenharia de Produção pela Universidade Federal do Rio de Janeiro. Atualmente é Professor Associado da Universidade Federal Fluminense.

Pesquisa com ênfase em Gerência de Riscos, Manutenção, Segurança e Meio Ambiente Industrial.