

RAFAEL AUGUSTO GALO FERNANDES

**SISTEMA DE INFERÊNCIA *FUZZY* PARA DETECÇÃO DE ESTOLES EM
MOTORES DE FUNDO EM OPERAÇÕES DE FLEXITUBO EM POÇOS
PETROLÍFEROS**

Guaratinguetá - SP
2024

Rafael Augusto Galo Fernandes

**SISTEMA DE INFERÊNCIA *FUZZY* PARA DETECÇÃO DE ESTOLES EM
MOTORES DE FUNDO EM OPERAÇÕES DE FLEXITUBO EM POÇOS
PETROLÍFEROS**

Dissertação apresentada à Faculdade de Engenharia do Campus de Guaratinguetá, Universidade Estadual Paulista, como para obtenção do título de Mestre em Engenharia Mecânica.

Orientador: Prof. Dr. José Alexandre Matelli

Guaratinguetá - SP
2024

F363s	Fernandes, Rafael Augusto Galo Sistema de inferência <i>Fuzzy</i> para detecção de estoques em motores de fundo em operações de flexitubo em poços petrolíferos / Rafael Augusto Galo Fernandes - Guaratinguetá, 2024. 52 f : il. Bibliografia: f. 50-52 Dissertação (Mestrado) – Universidade Estadual Paulista, Faculdade de Engenharia e Ciências de Guaratinguetá, 2025. Orientador: Prof. Dr. José Alexandre Matelli 1. Sistemas difusos. 2. Sistemas de controle inteligente. 3. Indústria petrolífera. 4. Lógica difusa. I. Título. CDU 007.52(043)
-------	---

IMPACTO POTENCIAL DESTA PESQUISA

Essa pesquisa visa a diminuição dos incidentes relacionados a operações de flexitubo com motores de fundo. A redução desses incidentes levará a diminuição do tempo de retrabalho, portanto a economia de materiais e combustível utilizado durante os trabalhos. Também aumenta a segurança do trabalhador, pois esses retrabalhos envolvem trabalho manual e com manejo de objetos pesados, que podem causar acidentes com os trabalhadores.

POTENTIAL IMPACT OF THIS RESEARCH

This research aims to reduce incidents related to coiled tubing operations with downhole motors. Reducing these incidents will lead to a decrease in rework time, thereby saving materials and fuel used during operations. It also enhances worker safety, as rework involves manual labor and handling of heavy objects, which can result in accidents.

RAFAEL AUGUSTO GALO FERNANDES

Sistema de inferência fuzzy para detecção de estoques em motores de fundo em operações de flexiturbo

Dissertação apresentada à Universidade Estadual Paulista (UNESP), Faculdade de Engenharia e Ciências de Guaratinguetá, para obtenção do título de Mestre em Engenharia

Data da defesa: 29/10/2024

Banca Examinadora:

Documento assinado digitalmente
 **JOSE ALEXANDRE MATELLI**
Data: 06/11/2024 13:14:33-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. JOSÉ ALEXANDRE MATELLI
Orientador - UNESP

 Documento assinado digitalmente
Jonny Carlos da Silva
Data: 05/11/2024 09:56:04-0300
CPF: ***.515.064-**
Verifique as assinaturas em <https://v.ufsc.br>

Prof. Dr. JONNY CARLOS DA SILVA
Universidade Federal de Santa Catarina

Documento assinado digitalmente
 **PALOMA MARIA SILVA ROCHA RIZOL**
Data: 05/11/2024 07:29:12-0300
Verifique em <https://validar.iti.gov.br>

Profa. Dra. PALOMA MARIA SILVA ROCHA RIZOL
UNESP

DADOS CURRICULARES

RAFAEL AUGUSTO GALO FERNANDES

NASCIMENTO	19.04.1985 – Guaratinguetá / SP
FILIAÇÃO	Arlindo de Deus Fernandes Maria de Lourdes Galo
2004/2010	Graduação em Engenharia Elétrica FEG / UNESP
2020/2022	Pós graduação Latu Sensu MBA em Finanças e Controladoria USP / ESALQ

Dedico este trabalho á minha mãe Maria de
Lourdes que me ajudou em toda essa jornada.

AGRADECIMENTOS

Agradeço ao meu orientador Prof. Dr. José Alexandre Matelli e a Profa. Dra. Paloma Maria Silva Rocha Rizol por todo apoio dado durante esse trabalho. Foram eles que ministraram as disciplinas despertaram meu interesse aos assuntos tratados nesse trabalho, e também foram eles que tiveram ativa participação na escrita do texto. Agradeço também ao Prof. Dr. Andreas Nascimento pela ajuda dada a esse projeto.

O presente trabalho foi realizado com apoio da UNESP/FEG.

“Só realmente vence aquele que um dia já perdeu. Quem nunca perdeu ou errou, vencedor não é.”;

Rafael Fernandes

RESUMO

Os Motores de Deslocamento Positivo (PDM) são utilizados no campo petrolífero, seja na perfuração ou em operações com flexitubo visto que proporcionam uma maior taxa de penetração e a possibilidade de perfuração de poços horizontais. Para operações de flexitubo, os PDMs podem perfurar através de obstruções e permitem que poços com restrições que impeçam ou diminuam sua capacidade de produção voltem as suas condições ideais. Um dos maiores desafios ao usar essas ferramentas é o travamento de motor, também conhecido como estol (do inglês *stall*), o que pode levar a sérios danos ao PDM e atraso nas operações de perfuração e *workover*. Esses eventos, que resultam em perdas de centenas de milhares de dólares, dependem principalmente de operadores altamente treinados e totalmente focados na operação do equipamento. Se um PDM sofrer perda de rotação, o bombeio precisa ser interrompido imediatamente ou a ferramenta pode sofrer danos permanentes. Este artigo descreve o uso de uma Sistema de Inferência *Fuzzy* (FIS) para detectar os eventos de estol quando tão logo eles se iniciem utilizando-se dos dados de aquisição de uma operação com PDM em uma unidade de flexitubo. Nesse sistema a saída do FIS poderia, então, acionar um alarme para o operador tomar as medidas adequadas, ou cessar instantaneamente o bombeio de fluídos desarmando a unidade de bombeio. O FIS foi implementado em Python e testado com dados reais. O sistema analisou 68.458 pontos de aquisição e detectou 94% dos eventos de paralisação nesses dados durante seus primeiros segundos, enquanto, durante o trabalho real, um operador pode levar mais tempo para perceber esse evento e tomar as devidas providências, ou mesmo realizar ação alguma. Se o FIS fosse aplicado em um sistema real de aquisição, poderia reduzir as sobre pressurização do PDM devido ao estols, levando a um aumento de sua vida útil e diminuição de falhas prematuras. Até o momento não existe nenhum sistema similar no mercado ou divulgado e este tipo de operação é totalmente executado usando apenas a supervisão humana.

PALAVRAS-CHAVE: flexitubo; motor de deslocamento positivo; lógica *fuzzy*; indústria de petróleo e gás

ABSTRACT

Positive Displacement Motors (PDM) are used in the oilfield, either in drilling or in coiled tubing (CT) operations. They provide a higher rate of penetration and the possibility of drilling horizontal wells. For coiled tubing operations, PDMs can mill through obstructions and enable shut-in wells to work again. One of the major challenges while using these tools is the motor stalling, which can lead to serious damage to the PDM and lost time events in drilling and workover rigs. These events result in total losses of hundreds of thousands of dollars, and their avoidance mostly depends on trained and fully aware equipment operators. If a PDM starts to stall, the pumping needs to be halted immediately or the tool may fail. This paper describes the use of a *Fuzzy Inference System* (FIS) to detect the stalling events as they start to happen using the acquisition data from the coiled tubing unit, the output of the FIS could then trigger an alarm for the operator to take the proper action or remotely stop the pump. The FIS was implemented in Python and tested with real CT milling acquisition data. When tested using real data, the system analyzed 68,458 acquisition points and detected 94% of the stalling events across this data during its first seconds, whereas, during the real job, a CT operator could take longer to notice this event and take the proper action, or even take no action. If the FIS was applied on a real coiled tubing acquisition system, it could reduce PDMs over-pressurization due to stalling, leading to an increase on its useful life and decrease on premature failure. As of now there is no similar system in the market or published and this kind of operation is fully performed using human supervision only.

KEYWORDS: coiled tubing; positive displacement motor; fuzzy logic; oilfield

LISTA DE FIGURAS

Figura 1 - Operação do PDM	16
Figura 2 – Diferença entre lógica clássica e lógica <i>fuzzy</i>	23
Figura 3 - Exemplo de uso de conjunto fuzzy	24
Figura 4 – Sistema de inferência <i>Fuzzy</i>	25
Figura 5 - Sensores instalados no sistema	28
Figura 6 – Fluxo de dados do sistema	33
Figura 7 – Descrição gráfica da variável Δ_{CP}	35
Figura 8 – Descrição gráfica da variável σ_{CP}	36
Figura 9 – Descrição gráfica da variável σ_w	37
Figura 10 – Descrição gráfica da variável PDM Status	38
Figura 11 – Descrição gráfica da variável Flow Restriction	39
Figura 12 - Funções de Pertinência de Entrada	42
Figura 13 - Funções de Pertinência para as saídas	43
Figura 14 - Gráfico para pontos de dados do caso de pré-teste e saídas do FIS	45
Figura 15 - Gráfico para pontos de dados do conjunto de dados 1 e saídas FIS	46
Figura 16 - Gráfico para pontos de dados do conjunto de dados 2 e saídas FIS	46
Figura 17 - Gráfico para pontos de dados do conjunto de dados 3 e saídas FIS	47

LISTA DE TABELAS

Tabela 1 - Funções de pertinência para a variável Δ_CP (Δ_CP)	34
Tabela 2 - Funções de pertinência para a variável $CP_deviation$ (σ_CP)	35
Tabela 3 - Funções de pertinência para a variável $CTW_deviation$ (σ_w)	36
Tabela 4 - Funções de pertinência para variável PDM Status	38
Tabela 5 - Funções de pertinência para variável Flow Restriction.....	39
Tabela 6 - Base de regras do FIS	41

LISTA DE ABREVIATURAS E SIGLAS

BHA	<i>Bottom Hole Assembly</i>
BOP	<i>Blow Out Preventer</i>
CP	<i>Circulating Pressure</i>
CT	<i>Coiled Tubing</i>
CTW	<i>Coiled Tubing Weight</i>
EH	<i>Extremely High</i>
EL	<i>Extremely Low</i>
FIS	<i>Fuzzy Inference System</i>
IA	<i>Inteligência Artificial</i>
MF	<i>Membership Function</i>
ML	<i>Machine Learning</i>
OD	<i>Outside Diameter</i>
PDM	<i>Positive Displacement Motors</i>
ROP	<i>Rate of Penetration</i>
VH	<i>Very High</i>
VL	<i>Very Low</i>
WHP	<i>Well Head Pressure</i>
WOB	<i>Weight on Bit</i>

LISTA DE SÍMBOLOS

m	metro
psi	libra por polegada quadrada
lbf	libra força

SUMÁRIO


1	INTRODUÇÃO	16
2	REVISÃO BIBLIOGRÁFICA.....	21
2.1	Trabalhos relacionados	21
2.2	Sistemas inteligentes baseados em lógica <i>Fuzzy</i>	22
2.3	Princípios da lógica fuzzy.....	22
2.4	Teoria dos conjuntos <i>Fuzzy</i>	23
2.5	Sistema de inferência fuzzy	25
2.6	Tipos de modelos fuzzy	26
3	MATERIAIS E MÉTODOS.....	27
3.1	<i>Fuzzy Inference System</i>	27
3.2	Dados medidos pela unidade de ct	27
3.3	Cálculos internos	29
3.4	Implementação do sistema FIS.....	33
3.5	Variáveis de entrada do FIS.....	33
3.6	Variáveis de saída do FIS	37
3.7	Base de regras	39
4	RESULTADOS.....	42
4.1	Teste do FIS.....	42
4.2	Execução do fis com base de dados.....	43
4.3	Análise de resultados	44
4.4	Discussão geral	47
5	CONSIDERAÇÕES FINAIS	49
	REFERÊNCIAS.....	50

1 INTRODUÇÃO

Os Motores de Deslocamento Positivo (PDM) são amplamente utilizados no campo petrolífero para perfurar a formação em direção ao reservatório ou para remover mecanicamente alguma restrição do poço. Eles foram desenvolvidos na década de 1940 e comercializados na década de 1950 (CHEN *et al.*, 2016).

Também chamados de motores de lama ou de fundo, os PDMs são utilizados para melhorar a taxa de penetração (ROP), onde o PDM converte o fluxo de lama de energia em energia mecânica rotativa, como demonstra Figura 1 ao gerar a rotação da broca quando o fluido de perfuração é bombeado. O desempenho do PDM pode ser controlado pela configuração do lóbulo do rotor/estator, velocidade de rotação e torque (CHEN *et al.*, 2016).

Figura 1 - Operação do PDM



Fonte: Chen *et al.* (2016)

A perfuração com motores de deslocamento positivo domina as operações de perfuração de campos petrolíferos devido às suas vantagens operacionais e econômicas em relação à perfuração rotativa convencional (ZHANG *et al.*, 2020).

Dessa forma, os PDMs também são muito importantes na indústria de Coiled Tubing (CT), onde são usados principalmente para usinar tampões de isolamento após operações de fraturamento hidráulico, que são comuns em ambientes de gás de folhelho, sendo uma das

partes cruciais do *Bottom Hole Assembly* (BHA), que é o conjunto de ferramentas utilizadas dentro do poço para sua perfuração.

Estima-se que entre 100.000 a 140.000 plugues compostos sejam instalados e usinados a cada ano somente nos Estados Unidos. A remoção eficiente desses plugues compostos é crítica para alcançar eficiências operacionais tanto para o operador quanto para as companhias de serviço (CRAIG *et al.*, 2012).

No PDM, o rotor tem um lóbulo a menos que o estator, o que deixa um espaço por onde o fluido circula e força o rotor para o próximo lóbulo livre no estator, essa rotação resultante gera a rotação constante do eixo do motor e torque que é transferido para a broca (CRAIG *et al.*, 2012).

Segundo Anuanwu, Klotz e Ulrich (2012), os PDMs são propensos a falhas, principalmente devido ao estol e à sobre pressão que esse evento produz. À medida que mais paradas são acumuladas ao longo do tempo, essa interrupção da perfuração pode resultar em perdas significativas de tempo produtivo de perfuração.

Com isso, um motor danificado no fundo do poço pode levar a uma perda de até centenas de milhares de dólares em uma plataforma de perfuração offshore. A parada também pode deixar grandes cortes do material sendo fresado dentro do poço, que são mais difíceis de circular de volta à superfície devido ao seu tamanho e formato, levando a uma limpeza inadequada do poço e, finalmente, a uma situação de tubo preso.

Conforme afirma Craig *et al.* (2012),

Aplicar muito peso à broca/fresadora aumenta o risco de parada do motor. As paradas levam a uma redução na vida útil do motor, aumento da fadiga do flexitubo, operação ineficiente e aumento significativo no risco de deixar grandes pedaços de material composto. Esses grandes pedaços compostos aumentam consideravelmente o risco de o BHA ficar preso no poço e o risco de que os pedaços bloqueiem o equipamento de fluxo de retorno (CRAIG *et al.*, 2012).

Como a água ou a lama tem baixa compressibilidade, a pressão pode aumentar muito rapidamente no caso de uma obstrução repentina ao fluxo, portanto, um operador distraído não tem tempo de reagir e interromper a operação. Evitar ou minimizar o tempo que o PDM para durante uma operação de fresamento é uma das principais atribuições do operador do equipamento durante o trabalho (STHEOPHILUS *et al.*, 2017).

No entanto, este mesmo operador está sujeito aos seguintes erros humanos: erros perceptivos, quando o operador não observa que os dados exibidos pelos sensores são anormais; erros de habilidade, quando mesmo percebendo que os parâmetros são anormais, ele não chega a conclusão correta sobre o que está acontecendo de errado com a operação; e

erros de decisão, em que o operador reconhece a situação anormal corretamente, porém não toma as devidas providências para solucionar o problema (SELVIK e BELLANY, 2018).

Em um esforço para minimizar esses erros e seus efeitos prejudiciais, este trabalho estuda o uso de Inteligência Artificial (IA) nos dados disponíveis durante a operação com PDMs, pois tomada de decisões e solução de problemas operacionais são algumas das áreas de aplicação da IA na indústria petróleo e que já estão sendo discutidas na literatura (SOLANKI *et al.*, 2022), e disponibilizar aos operadores sistemas inteligentes que melhorem o processo de tomada de decisão pode evitar erros induzidos pelo homem (BELLO *et al.*, 2016).

Consequentemente, meios que auxiliem o operador a detectar esse estol e tomar as devidas providências motivaram esta pesquisa. Todos os dados disponíveis durante a operação de PDM com CT foram medidos em superfície e não há medição direta da rotação do PDM para diagnosticar diretamente uma parada. A interpretação dos parâmetros de superfície em conjunto é exigida do operador a cada segundo para avaliar adequadamente o que está acontecendo com a ferramenta no fundo do poço (SOLANKI *et al.*, 2022).

Considerando que o operador é humano e sujeito a erros, este trabalho visa utilizar um algoritmo computacional para supervisionar os dados na superfície, reconhecer qualquer situação anormal e informá-la ao usuário. Sircar (2021) exemplificou que muitos problemas na perfuração poderiam ser resolvidos usando Machine Learning (ML).

No entanto, o caso em estudo apresenta duas grandes limitações para o uso de ML: primeiro, o conjunto de dados disponível para desenvolvimento é relativamente pequeno, contendo dados de quatro operações com PDM em poços diferentes, porém com o mesmo modelo de PDM e fluido; segundo, de acordo com Noshi e Schubert (2018), apesar da indústria do petróleo contar com um grande número de sensores, ela também conta com a interação humana com o equipamento, que não é registrada nos dados e apenas aplicando uma técnica de aprendizado de máquina, que consideraria somente esses dados do sensor levariam a correlações incorretas entre entradas e saídas.

Como a operação com PDM é fortemente dependente da interação humana, um algoritmo de ML foi considerado inadequado para esse propósito e outras técnicas de IA como a lógica *Fuzzy* tiveram que ser consideradas.

No esforço de melhorar o desempenho na resolução de problemas complexos, os sistemas de inferência *fuzzy* (FIS) buscam emular o raciocínio humano, imitando seu funcionamento por meio de um mecanismo de inferência baseado em relações de causa e

efeito entre variáveis categóricas e considerando a incerteza associada aos valores dessas variáveis (ZIMMERMANN, 1991).

Ao armazenar o conhecimento sobre o problema em uma base de regras de decisão, esse tipo de sistema permite estimar saídas para diversos tipos de problemas, como os que envolvem controle de processos, classificação de padrões e aproximação funcional de funções lineares e não lineares (KAHRAMAN, 2008).

A lógica *fuzzy* utiliza variáveis linguísticas com graus de pertinência, tornando-a mais próxima da forma humana de pensar e raciocinar, ao invés de utilizar valores e funções numéricas puras, permitindo uma abordagem mais intuitiva para a solução de problemas. Zadeh (1965) descreveu pela primeira vez o conjunto Fuzzy, que posteriormente foi modelado matematicamente por Takagi e Sugeno (1985).

A Teoria dos Conjuntos Fuzzy, proposta por Zadeh (1965), é uma ferramenta poderosa para modelar sistemas compostos por elementos com contornos incertos, definidos por propriedades subjetivas ou atributos imprecisos. Essa teoria é particularmente adequada para modelar sistemas que envolvem incerteza e imprecisão devido à lógica que define o grau de inclusão (ou pertinência) de elementos em conjuntos *fuzzy*.

Ao contrário da teoria de conjuntos clássica, onde um conjunto é definido por uma função característica, a Teoria de Conjuntos Fuzzy modela um conjunto *fuzzy* através de uma função de pertinência, permitindo níveis parciais de inclusão, ou seja, considera os valores no intervalo para representar o grau de pertinência de um elemento em um conjunto, em vez de um valor binário de 0 ou 1. Isso permite uma representação mais realista da incerteza e imprecisão em sistemas complexos (ZADEH, 1965).

Dessa forma, ao utilizar um mecanismo de inferência baseado em relações de causa e efeito entre variáveis categóricas, esses sistemas podem estimar saídas para uma ampla gama de problemas, incluindo controle de processo, classificação de padrão e aproximação funcional de funções lineares e não lineares (LIMA e CARPINETTI, 2015).

A chave para o sucesso desses sistemas está em sua capacidade de armazenar conhecimento sobre o problema em uma base de regras de decisão, o que permite estimativas de saídas mais precisas. Isso os torna uma ferramenta inestimável para empresas e organizações que buscam melhorar seu desempenho na solução de problemas complexos (BARROS e FERNANDES, 2019).

Apesar de todos os dados disponíveis durante a operação com PDM serem numéricos (como pressão, peso e vazão), o julgamento do operador ainda é subjetivo sobre se um estol está acontecendo em um determinado momento e se ele/ela deve parar de bombear fluido

através do PDM ou não. Em tais processos de tomada de decisão não-booleanos, a abordagem *Fuzzy* para esse problema parece ser promissora, pois leva em conta a incerteza e imprecisão da decisão humana na definição de critérios precisos para a tomada de decisão (ZADEH, 1965).

Nas seções a seguir é proposto um Sistema de Inferência Lógica Fuzzy (FIS) com 3 entradas e 2 saídas que monitorará os parâmetros de superfície de uma operação de flexitubo e detectará a parada do PDM em seus segundos iniciais, dando tempo suficiente para que o bombeamento seja interrompido minimizando as chances de um dano ao PDM e prolongando sua vida útil.

O sistema deve detectar o estol do motor o mais rápido possível, usando apenas os dados disponíveis dos sensores de superfície da unidade de CT e outros dados pré-configurados relevantes. A configuração das entradas, saídas, banco de dados de conhecimento (regras *fuzzy*) e o cálculo é feito com o apoio de um operador especialista em operações com PDM.

Essa pesquisa se justifica pelo fato de não haver sistema similar no mercado, ou alguma pesquisa relacionada publicada nos sistemas de busca acadêmicos. Uma vez aplicado em uma situação real, esse sistema poderia ocasionar uma considerável economia de tempo e recursos em operações com PDM, tao bem como o aumento da segurança das operações.

As seções seguintes deste artigo estão estruturadas da seguinte forma. A seção de método descreve a arquitetura do FIS, incluindo entradas, saídas, conjunto de regras e pré-cálculos do sistema. A seção de resultados e discussão apresenta as saídas geradas pelo FIS usando o conjunto de dados de aquisição disponível para teste. A precisão do FIS em detectar os estoques é avaliada, e uma discussão geral sobre o sistema é feita. Por fim, a seção de conclusão finaliza este trabalho.

2 REVISÃO BIBLIOGRÁFICA

2.1 TRABALHOS RELACIONADOS

A maior parte dos esforços na área de IA a serem aplicados em PDMs no campo petrolífero são referentes à manutenção ou análise de dados de sensores na própria ferramenta. Os estudos mais recentes que usam dados de superfície em conjunto com IA para ajudar o perfurador ou operador de CT a operar corretamente o motor ou entender sua condição real durante o fundo do poço são mencionados abaixo.

Demirer (2020) apresentou um sistema que usa Programação Inteira Mista (MIP) para fornecer os parâmetros de perfuração ideais para alcançar uma trajetória de poço esperada. Como proposto por Zhao (2019), o sistema considerou as propriedades do PDM, broca e dados em tempo real da plataforma e definiu os comandos de direção ideais, como face da ferramenta e relação de direção, que permitem que a trajetória do poço seja o mais próximo possível do plano. Este sistema foi uma melhoria em sistemas similares.

Em outro aspecto, Zhang (2020) comparou os dados de fundo de poço e superfície adquiridos de vários PDMs e combinou-os para calcular a eficiência real do motor. Ao juntar a pressão da bomba, taxa de fluxo e RPM do top drive da superfície mais a velocidade rotacional do fundo do poço com a especificação PDM, a velocidade rotacional real, torque e entrada de energia versus saída (eficiência) foram calculadas. Neste trabalho, ele definiu uma correlação entre os dados de superfície adquiridos e a eficiência real do PDM e a degradação dessa eficiência ao longo do tempo. Segundo o autor, esse fluxo de trabalho pode ser usado para estimar a degradação do motor em uma aplicação em tempo real.

No estudo de Kamyab (2020), o autor usou um sistema baseado em regras para detectar em tempo real em que estágio do programa de perfuração a sonda está (por exemplo, descendo ou subindo coluna, perfurando, trocando lama) e determinar se o programa de perfuração passo a passo está sendo seguido apropriadamente. Essa IA monitorará constantemente todos os parâmetros da superfície e os comparará com as etapas pré-programadas, que incluem ações que o perfurador deve executar em relação ao movimento do tubo de perfuração, bombeamento de fluidos e manutenção do WOB e pressões conforme suas instruções.

2.2 SISTEMAS INTELIGENTES BASEADOS EM LÓGICA *FUZZY*

Sistemas inteligentes baseados em lógica *fuzzy* são um tipo de inteligência artificial que usa lógica *fuzzy*, também chamados de lógica nebulosa ou difusa, para tomar decisões. A lógica *fuzzy* é um conceito matemático que permite incerteza e imprecisão na tomada de decisões. Isso significa que, em vez de depender de regras estritas e resultados binários, os sistemas baseados em lógica *fuzzy* podem tomar decisões com base em uma gama de possibilidades e graus de certeza (LIMA e CARPINETTI, 2015).

Esses sistemas são usados em uma variedade de aplicações, incluindo robótica, sistemas de controle e processos de tomada de decisão. Eles são particularmente úteis em situações em que há um alto grau de incerteza ou em que os sistemas tradicionais baseados em regras podem não ser eficazes (ZIMMERMANN, 1991).

No geral, os sistemas inteligentes baseados em lógica *fuzzy* oferecem uma abordagem flexível e adaptável à tomada de decisões que pode ajudar a melhorar a eficiência e a precisão em uma ampla gama de setores (TANSCHKEIT, 2008).

2.3 PRINCÍPIOS DA LÓGICA *FUZZY*


Os princípios da lógica *fuzzy* são baseados na ideia de que as coisas não são apenas verdadeiras ou falsas, mas podem ter graus de verdade. Isso significa que a lógica *fuzzy* permite a representação de incertezas e imprecisões em um sistema (COSTA et al., 2005).

A lógica *fuzzy* é baseada em conjuntos *fuzzy*, que são conjuntos cujos elementos têm graus variáveis de pertinência. Em outras palavras, um elemento pode pertencer parcialmente a um conjunto, dependendo do grau de sua associação com as características do conjunto (POSSELT, 2008).

Os conjuntos *fuzzy* são uma importante ferramenta da teoria dos conjuntos que permite lidar com a incerteza e a imprecisão presentes em muitos problemas do mundo real. Eles foram introduzidos na década de 1960 pelo matemático Lotfi Zadeh, como uma extensão dos conjuntos clássicos, que são definidos por uma função característica que atribui valor 0 ou 1 a cada elemento do conjunto, indicando se ele pertence ou não ao conjunto (JUNIOR; NOVAKOWSKI, 2005).

Ao contrário dos conjuntos clássicos, conforme Figura 2, os conjuntos *fuzzy* permitem que um elemento possa pertencer parcialmente a um conjunto, com graus de pertinência variando entre 0 e 1. Isso significa que um elemento pode ser considerado mais ou menos pertencente a um conjunto, dependendo do contexto em que está sendo avaliado.

Figura 2 – Diferença entre lógica clássica e lógica *fuzzy*



Fonte: Costa *et al.* (2005)

Outro princípio importante da lógica *fuzzy* é o uso de funções de pertinência para descrever a relação entre um elemento e um conjunto. Essas funções atribuem valores numéricos aos elementos com base em sua proximidade com as características do conjunto (POSSELT, 2008).

Esses operadores são diferentes dos operadores tradicionais da lógica booleana, pois eles permitem que os valores de verdade sejam expressos em termos de graus de pertinência. Isso significa que a lógica *fuzzy* é capaz de lidar com informações imprecisas ou incertas, o que é muito útil em situações onde as informações disponíveis são incompletas ou ambíguas (REZENDE, 2003).

Além disso, a lógica *fuzzy* pode ser aplicada em uma ampla variedade de áreas, incluindo controle de processos industriais, sistemas de tomada de decisão e inteligência artificial. Em resumo, a lógica *fuzzy* é uma ferramenta poderosa para lidar com a complexidade do mundo real e pode ajudar a melhorar a eficiência e precisão em muitas áreas diferentes (JUNIOR, NOVAKOWSKI, 2005).

2.4 TEORIA DOS CONJUNTOS FUZZY

Os conjuntos *fuzzy* foram desenvolvidos para determinar o grau em que um elemento pertence a um determinado conjunto, usando graus de pertinência (μ) que são valores no intervalo de $[0;1]$. Isso permite a identificação dos elementos que pertencem a um grupo e seu respectivo grau de pertencimento (JÚNIOR; NOVAKOWSKI, 2005).

A representação de conjuntos difusos depende da natureza e das dimensões do universo que está sendo representado. Quando é necessário representar conjuntos que contenham um universo pequeno, a melhor solução é a utilização de uma lista, que apresenta todos os elementos do universo separados por vírgulas, sendo cada elemento composto pelo grau de pertinência e o valor do termo. Quando o universo representado contém um grande número de elementos, ele deve ser representado por um gráfico de sua função de pertinência, denominado diagrama de Hassi-Euler (H-E) (REZENDE, 2003).

A Figura 3 apresenta um exemplo de determinação de conjuntos *fuzzy*. O universo dos elementos está representado no item 1 da figura, constituído por idades. No item 2 da figura, são criados três conjuntos: jovem, adulto e idoso. No item 3 da figura, estão representados os graus de pertencimento aos grupos em relação aos elementos do universo. Pode-se observar que, aos trinta anos, um indivíduo tem um grau de pertinência de 0,5 em relação ao conjunto jovem, 0,4 em relação ao conjunto adulto e 0,1 em relação ao conjunto antigo (COSTA *et al.*, 2005).

Figura 3 - Exemplo de uso de conjunto fuzzy

1)	$U = \{5, 10, 20, 30, 40, 50, 60, 70\}$				
2)	Conjuntos difusos: jovens, adultos, velhos				
3)	Idades	Jovens	Adultos	Velhos	(μ)
	5	1,0	0,0	0,0	
	10	1,0	0,0	0,0	
	20	0,8	0,2	0,0	
	30	0,5	0,4	0,1	
	40	0,2	0,4	0,4	
	50	0,1	0,3	0,6	
	60	0,0	0,2	0,8	
	70	0,0	0,0	1,0	

Fonte: Junior; Novakowski (2005)

Os conjuntos difusos são uma ferramenta poderosa para lidar com a incerteza e a imprecisão na análise de dados e na tomada de decisões. Ao fornecer uma maneira de

quantificar o grau de pertinência de um elemento em um conjunto, eles permitem uma análise mais detalhada e precisa de sistemas complexos. O uso de conjuntos difusos está se tornando cada vez mais comum em áreas como inteligência artificial, sistemas de controle e mineração de dados, e provavelmente continuará crescendo em importância nos próximos anos (JUNIOR, NOVAKOWSKI, 2005).


2.5 SISTEMA DE INFERÊNCIA FUZZY

O sistema de inferência *fuzzy* (FIS) é um tipo de inteligência artificial que utiliza a lógica difusa para tomar decisões com base em dados imprecisos ou incertos. É comumente usado em sistemas de engenharia e controle para melhorar a precisão e a eficiência (POSSELT, 2008).

O FIS funciona obtendo dados de entrada e aplicando um conjunto de regras a eles. Essas regras são baseadas em variáveis linguísticas, que são definidas por conjuntos nebulosos. O sistema então usa essas regras para tomar uma decisão ou gerar um resultado (TANSCHKEIT, 2008).

Exemplificando, conforme Figura 4, a estrutura básica de um FIS inclui três componentes principais: o fuzzificador, o mecanismo de inferência e o defuzzificador. O fuzzificador pega os dados de entrada e os converte em conjuntos fuzzy, que são variáveis linguísticas que representam o grau de pertinência de um valor em um determinado conjunto. O mecanismo de inferência usa regras para tomar decisões com base nos conjuntos fuzzy, e o defuzzificador converte a saída fuzzy de volta em um valor nítido que pode ser usado para controlar um sistema (TANSCHKEIT, 2008).

Figura 4 – Sistema de inferência *Fuzzy*



Fonte: Tanscheit (2008)

No geral, o FIS é uma ferramenta poderosa que pode melhorar muito a precisão e a eficiência de sistemas complexos. Ao utilizar lógica difusa e variáveis linguísticas, esses sistemas podem tomar decisões com base em dados imprecisos ou incertos, tornando-os ideais para uso em uma ampla gama de aplicações (TANSCHKEIT, 2008).

2.6 TIPOS DE MODELOS FUZZY

Os modelos difusos ou *fuzzy* são um tipo de modelo matemático usado para representar informações incertas ou vagas. Existem vários tipos diferentes de modelos difusos que podem ser usados dependendo da aplicação específica (SOUZA e MESQUITA, 2010).

Um tipo de modelo *fuzzy* é o modelo Mamdani, que é comumente usado em sistemas de controle. Este modelo utiliza regras nebulosas para mapear entradas para saídas, e é frequentemente utilizado em situações onde há necessidade de controlar um sistema baseado em dados imprecisos ou incertos (MAMDANI; ASSILIANO, 1975).

Outro tipo de modelo *fuzzy* é o modelo Takagi-Sugeno, que é frequentemente usado na modelagem de sistemas complexos. Este modelo usa um conjunto de funções lineares para aproximar o comportamento de um sistema e é particularmente útil em situações onde existem muitas variáveis que precisam ser consideradas (SOUZA e MESQUITA, 2010).

No geral, entender os diferentes tipos de modelos difusos pode ser extremamente útil em uma variedade de aplicações. Ao selecionar o modelo apropriado para uma determinada situação, é possível representar e analisar com mais precisão sistemas e dados complexos.

3 MATERIAIS E MÉTODOS

3.1 FUZZY INFERENCE SYSTEM


Para esse estudo foi utilizado um FIS baseado em regras pré-determinadas de acordo com o especialista em operação de PDMs. As entradas do FIS correspondem aos dados de operação do PDM capturados e registrados pela unidade de CT. Esses dados entram no FIS e passam pela interface de fuzzificação, que converte os dados do mundo real em valores linguísticos. A partir desses valores linguísticos, o mecanismo de inferência infere os valores das saídas *fuzzy* de acordo com as regras pré-determinadas no sistema. As saídas *fuzzy* passam então pela interface de defuzzificação, gerando um valor de ativação específico para cada saída. As regras *fuzzy* que compõem a base de conhecimento suportam os processos de fuzzificação, defuzzificação e inferência. “O motor de inferência é um mecanismo de raciocínio que executa o procedimento de inferência sobre as regras de controle fuzzy e as condições dadas para derivar ações de controle razoáveis. É a parte central de um sistema de controle difuso” (FENG, 2006).

Neste trabalho, o sistema FIS com 3 variáveis de entrada e 2 variáveis de saída foi implementado utilizando Python e as bibliotecas SciKit Learn e skFuzzy.

Para a facilidade de entendimento dos operadores e especialistas, as pressões são medidas em “psi” (libras por polegada quadrada), as profundidades em metros, as forças em “lbf” (libra-força) e os pequenos comprimentos em “in” (polegadas), visto que essas são as unidades usualmente utilizadas na indústria petrolífera.

3.2 DADOS MEDIDOS PELA UNIDADE DE CT

Durante as operações com PDM, existem apenas 3 variáveis sendo medidas em tempo real e ilustradas na figura abaixo.

Figura 5 - Sensores instalados no sistema

Fonte: Elaborado pelo Autor (2024).

3.2.1 Pressão Circulante / Circulating Pressure (CP)

Pressão que o fluido está sendo bombeado dentro do carretel do CT e que chega ao PDM. Geralmente é medido por um sensor de pressão de 4–20 mA na saída da unidade de bombeio de fluido. Neste trabalho, consideramos o valor médio de CP durante o bombeamento e rotação livre sem nenhum peso na broca (WOB) aplicado.

A unidade utilizada para essa variável é o *psi* (libras por polegadas quadrada).

3.2.2 Peso CT / Coiled Tubing Weight (CTW)

O peso do tubo de CT pendurado no poço. É medido por uma célula de carga capacitiva sob a cabeça injetora. A célula de carga é zerada antes de iniciar a descida do PDM e do CT no poço, de modo que o peso total medido corresponda à soma do peso da seção de CT pendurada no poço, o peso das ferramentas de fundo de poço, a força de tração e o WOB aplicado pelo PDM. O atrito entre os tubos de enrolamento, BHA e a completação do poço é refletido no valor do peso medido e deve ser levado em consideração ao estimar o peso esperado para a operação.

Neste trabalho, consideramos a média de todas as leituras do peso durante a execução dos tubos no furo com o PDM instalado. Esse atrito já está incluso no valor do peso tomado como referência.

A unidade utilizada para essa variável é a libra-força (lbf).

3.2.3 Pressão da Cabeça do Poço / *Well Head Pressure* (WHP)

Pressão dentro do poço no nível da superfície, sendo medida sob a cabeça do injetor geralmente por um transdutor de pressão de 4 a 20 mA. O operador precisa estar atento ao WHP para monitorar se os valores estão se aproximando das limitações dos equipamentos de superfície ou se o poço está saindo do controle. Com base no WHP, o operador pode decidir se o choke precisa ser trocado, se o poço precisa ser morto/controlado com fluido mais pesado ou, como último recurso, se o *blow out preventer* (BOP) precisa ser fechado para proteger a segurança do poço.

A unidade utilizada para essa variável é o *psi* (libras por polegadas quadrada).

3.3 CÁLCULOS INTERNOS

Nenhum dos dados adquiridos disponíveis é alimentado diretamente ao FIS e alguns cálculos intermediários são realizados antes de entregar os dados à interface de fuzzificação. Àquelas variáveis que resultam do valor medido por algum sensor, subtraído do *set point* ou valor esperado para o mesmo, se atribui a letra grega σ (sigma minúsculo). Já aquela que resulta da variação de uma variável ao longo do tempo, ou desde a medição anterior, se atribui a letra grega Δ (delta maiúsculo).

3.3.1 Desvio do Set Point do WHP

Neste trabalho, as alterações no WHP são utilizadas para corrigir tanto o CP quanto o CTW, e as respectivas interpretações pelo sistema. Para que o WHP seja útil, é necessário um parâmetro para monitorar a mudança no WHP durante a operação de fresamento (WHP) a partir do valor inicial ou ponto de ajuste (WHP_{sp}). Tal parâmetro é chamado de desvio WHP (σ_{WHP}) e é definido de acordo com a Equação (1).

$$\sigma_{WHP} = WHP - WHP_{sp} \quad (1)$$

A unidade utilizada para essa variável é o *psi* (libras por polegadas quadrada).

3.3.2 Força de Ejeção CT por Pressão do Poço (F_{ej})

Como o poço tem uma pressão muito maior do que a atmosférica, o tubo de CT está constantemente sujeito a uma força que tenta ejetá-lo para fora do poço. Essa força é proporcional ao WHP e à área da seção transversal do tubo de CT, conforme mostrado na Equação (2) onde D_{ct}^2 se refere ao diâmetro externo do tubo.

$$F_{ej} = (\pi D_{ct}^2 / 4) \sigma_{WHP} \quad (2)$$

Essa força atua contra o peso do CT sustentado pela cabeça injetora. Isso significa que essa força será sentida pela célula de carga e o valor do peso adquirido diminuirá de acordo com a Equação (3).

$$\Delta_W = -\Delta F_{ej} \quad (3)$$

A unidade utilizada para essa variável é a libra-força (lbf).

3.3.3 Variação de CP (Δ_{CP})

É estipulado que três leituras do CP são necessárias para calcular a mudança no CP. Isso é feito subtraindo o valor atual CT(t) da média das duas últimas leituras CP(t-1) e CP(t-2), conforme mostrado na Equação (4).

$$\Delta_{cp}(t) = CP(t) - \frac{CP(t-1) + CP(t-2)}{2} \quad (4)$$

Essa taxa de variação é muito importante porque nos permite diferenciar uma restrição de fluxo parcial de uma total. Uma restrição parcial de fluxo pode ocorrer se ocorrer uma das seguintes situações: (i) o operador fecha lentamente o retorno do poço; (ii) a densidade do fluido dentro do poço começa a mudar; (iii) se o motor estiver trabalhando com um alto WOB sobre um material duro.

Por outro lado, uma restrição total de fluxo provavelmente indicaria um evento de parada do motor, no qual é esperado que a pressão de bombeamento aumente instantaneamente. Qualquer outra coisa que bloqueie o caminho do fluido também pode levar a essa situação, como jatos de broca entupidos, fechamento abrupto do retorno do poço ou entupimento do tubo de CT. No entanto, pode não ser possível diferenciar nenhuma dessas situações analisando apenas o pico de pressão.

A unidade utilizada para essa variável é o *psi* (libras por polegadas quadrada).

3.3.4 Desvio do Set Point do CP (σ_{CP})

Como o desvio WHP (Equação (1)), este valor de parâmetro é definido como o valor de pressão medido subtraído do *set point* (valor de pressão esperado para aquela determinada vazão). Como nenhum modelo de pressão de bombeamento é usado para calcular a pressão, a pressão média durante o bombeamento com motor operando a vazio foi usada como ponto de ajuste. No entanto, devido ao CP ser medido a montante do WHP, uma correção é necessária, pois qualquer variação na WHP será sentida em igual valor na CP.

Todo o fluido bombeado entra no tubo de CT, flui para o fundo do poço por dentro do tubo onde atua o PDM, flui de volta pelo espaço anular CT/tubulação do poço e depois flui pelo *choque* (estrangulador), que é uma válvula de abertura ajustável utilizada para controle das pressões dentro do poço. Devido à proximidade da bomba e do manifold da bobina de CT, a queda de pressão entre eles é desprezada. A pressão medida na bomba ou manômetro da bobina CT (CP_{sp}) é a soma de todas essas perdas de pressão, conforme a Equação (4), reconhecendo que a pressão no *choke* e no WHP são iguais.

$$CP_{sp} = \Delta P_{tubo} + \Delta P_{PDM} + \Delta P_{retorno} + WHP \quad (5)$$

onde: ΔP_{string} é a perda de carga devido ao atrito do fluido dentro do tubo de CT; ΔP_{PDM} é a perda de pressão dentro do PDM que gera sua rotação e torque e ΔP_{an} é a perda de pressão ao fluido retornar no espaço anular entre o tubo de CT e as paredes do poço.

As perdas de carga ΔP_{string} e ΔP_{an} são sempre constantes para uma determinada vazão de bombeamento e utilizando um determinado fluido, e o fato de o PDM estar fresando ou não, não deve alterar esses parâmetros. O WHP é medido pela unidade de CT e registrado pelo sistema, então o efeito de qualquer flutuação do WHP no CP pode ser corrigido para a Equação (6).

$$\sigma_{CP} = \Delta P_{PDM} - \sigma_{WHP} \quad (6)$$

Essa correção evita interpretações errôneas sobre eventos em que alterações no WHP refletem no CP. Por exemplo, se o operador do *choke* realizar seu fechamento parcial durante uma operação com o PDM e aumentar o WHP em 500 psi, o CP aumentará na mesma proporção e poderia, sem essa correção, ser erroneamente interpretado como um estol do motor. No entanto, se o CP aumentar e o WHP seguir constante, pode-se inferir que esse aumento seja fruto do aumento de pressão no estator do motor e que o mesmo esteja entrando em um estol.

A unidade utilizada para essa variável é o *psi* (libras por polegadas quadrada).

3.3.5 Desvio do Set Point do Peso (σ_w)

Analogamente ao CP, há uma correção necessária porque o WHP gera uma força que tenta ejetar o tubo para fora do poço (ver Seção 3.3.2). Primeiro, o sistema define qual é o peso esperado para essa profundidade nessas condições de poço. Esse parâmetro pode ser obtido registrando o CTW enquanto o CT percorre livremente o poço como por Equação (7). Esta fórmula é válida desde que WHP seja nulo e não haja força externa (afrouxamento de peso ou tração) atuando no CT.

$$W_{sp} = CTW \quad (7)$$

O desvio de peso (σ_w) é calculado de acordo com a Equação (8) onde o peso medido (CTW) é subtraído pelo ponto de ajuste de peso (W_{sp}) e pela força de ejeção (F_{ej}) e, finalmente, do peso na broca (WOB) aplicado na parte inferior do PDM.

$$\sigma_w = CTW - W_{sp} - F_{ej} - WOB \quad (8)$$

O WOB é o único parâmetro da equação sem uma medição direta; no entanto, uma vez que o W_{sp} é igual ao CTW (consulte a Equação (7)), eles se anulam e isso resulta na Equação (9). Rearranjando a equação, chegamos ao WOB, que é parâmetro de interesse do sistema (Equação (10)).

$$\sigma_w = -F_{ej} - WOB \quad (9)$$

$$WOB = -F_{ej} - \sigma_w \quad (10)$$


A unidade utilizada para essa variável é a libra-força (lbf).

3.4 IMPLEMENTAÇÃO DO SISTEMA FIS

Os parâmetros definidos nas Seções 3.3.3 a 3.3.5 são usados como entradas para a interface de fuzzificação no FIS. Como o sistema é escrito em Python, as variáveis têm seus nomes convertidos para o alfabeto inglês simples da seguinte forma: “CP_deviation” para σ_{CP} ; “CTW_deviation” para σ_w e “delta_CP” para Δ_{CP}

A estrutura de fluxo de dados do sistema é representada na Figura 8. A maioria das variáveis adquiridas da unidade CT passa primeiro por algum cálculo para ser convertida nas três entradas do sistema, ou seja, delta_CP, CP_deviation e CTW_deviation (consulte a Seção 4.3).

Figura 6 – Fluxo de dados do sistema



Fonte: Elaborado pelo Autor (2024).

As regras também são definidas no sistema que irá executá-las juntas para definir os valores para ambas as saídas PDMStatus e FlowRestriction.

3.5 VARIÁVEIS DE ENTRADA DO FIS

Conforme descrito na seção anterior, o FIS é composto por 3 entradas que são definidas nos parágrafos abaixo.

3.5.1 Delta CP (Δ_{CP})

Para a variável de entrada Delta CP (Δ_{CP}) conforme explicado anteriormente na Equação (4), foi criada uma função de pertinência (MF) com 5 funções de pertinência triangular conforme a Figura 9. As variáveis linguísticas usadas para cada função são: “VL” para “Muito Baixo”, “L” para “Baixo”, “N” para “Normal”, “H” para “Alto” e “VH” para “Muito Alto” e os limites utilizados para cada valor estão descritos na Tabela 1 com os valores dados em “psi” (libras por polegada quadrada).


Os limites para cada função de pertinência e o universo do discurso são retirados do especialista que ajudou na criação do banco de regras. Se a pressão começar a subir mais de 30 psi (206 KPa) mas menos de 80 psi (551 kPa) na média dos últimos 2 s, habilitará a entrada H (High) no campo delta_CP.

Isso significa que esse valor ficará dentro do valor H (Alto) para delta_CP. Observe que o universo do discurso e os limites dos MFs trapezoidais tiveram que ser expandidos para longe dos valores de ativação de VL e VH, pois o sistema skFuzzy gerará um erro se um dado apontar fora desses limites for dado como entrada, e toda a execução do FIS será interrompida.

Tabela 1 - Funções de pertinência para a variável delta_CP (Δ_{CP})

delta_CP		Function Type	Limit Points			
			A	B	C	D
VH	Very High	Trapezoidal	30	80	500	500
H	High	Triangular	0	30	80	
N	Normal	Triangular	-30	0	30	
L	Low	Triangular	-80	-30	0	
VL	Very Low	Trapezoidal	-500	-500	-80	-30
Universe of discourse			-500			500

Fonte: Elaborado pelo Autor (2024).

Figura 7 – Descrição gráfica da variável delta_CP (Δ_{CP})

Fonte: Elaborado pelo Autor (2024).

3.5.2 Desvio CP (σ_{CP})


Para esta entrada, foram utilizadas as mesmas funções de pertinência acima, apenas os limites de cada função e o universo do discurso foi ajustado de acordo com o conhecimento especializado e mostrado na Tabela 2 com os valores dados em “psi” (libras por polegada quadrada).

Como exemplo, ao usar um PDM de diâmetro externo (OD) de 2–7/8” (73,152 mm), o operador de TC geralmente visa um diferencial de pressão de 200 psi (1380 kPa) a 800 psi (5516 kPa) ao bombear água ou salmoura leve a 2,8 bpm (445 l/min) taxa de bombeamento durante a moagem. Isso significa que esse valor ficará dentro do valor H (Alto) para o CP_deviation. A função de pertinência é representada na Figura 10.

Tabela 2 - Funções de pertinência para a variável CP_deviation (σ_{CP})

CP_deviation		Function Type	Limit Points			
			A	B	C	D
VH	Very High	Trapezoidal	200	800	3000	3000
H	High	Triangular	0	200	800	
N	Normal	Triangular	-200	0	200	
L	Low	Triangular	-800	-200	0	
VL	Very Low	Trapezoidal	-3000	-3000	-800	-200
Universe of discourse			-3000			3000

Fonte: Elaborado pelo Autor (2024).

Figura 8 – Descrição gráfica da variável CP_deviation (σ_{CP})

Fonte: Elaborado pelo Autor (2024).

3.5.3 Desvio de Peso (σ_w)


Finalmente, a terceira entrada para o sistema é o desvio do peso esperado durante a execução da fresagem do peso real medido. Conforme explicado anteriormente na Seção 4.3.5, o desvio do CTW do ponto de ajuste leva a uma medição indireta do WOB sendo aplicado, a diferença é que quando o PDM diminui o peso em qualquer elemento do fundo do poço, o σ_w assumirá negativos valores descritos na Equação (7).

Foram utilizadas as mesmas funções de pertinência das entradas anteriores, com universo e discurso e limites para cada função ajustados conforme Tabela 3 e Figura 11 com os valores dados em “lbf” (libra-força). Como exemplo, durante a fresagem é comum aplicar um WOB de 500 lbf (2224 N) a 1000 lbf (4448 N) que irá refletir em um -500 lbf a -1000 lbf no CTW_deviation e ativar o L (Low) função de membro. O universo do discurso e do MF trapezoidal também teve que ser expandido pelo mesmo motivo explicado na Seção 4.5.1.

Tabela 3 - Funções de pertinência para a variável CTW_deviation (σ_w)

CTW_deviation		Function Type	Limit Points			
			A	B	C	D
VH	Very High	Trapezoidal	500	1000	10000	10000
H	High	Triangular	0	500	1000	
N	Normal	Triangular	-500	0	500	
L	Low	Triangular	-1000	-500	0	
VL	Very Low	Trapezoidal	-10000	-10000	-1000	-500
Universe of discourse			-10000			10000

Fonte: Elaborado pelo Autor (2024).

Figura 9 – Descrição gráfica da variável CTW_deviation (σ_w)

Fonte: Elaborado pelo Autor (2024).

3.6 VARIÁVEIS DE SAÍDA DO FIS

O FIS é composto por 2 saídas, uma delas para sinalizar quando o PDM está travando e a outra para sinalizar quando a leitura da pressão é anormal, mas não há evidências para concluir que isso é devido ao PDM. De acordo com o especialista, uma leitura de CP acima do esperado ou o aumento repentino do CP só pode ser correlacionada a uma condição no PDM se o WOB estiver sendo aplicado.

A falta de WOB pode ser o resultado do PDM ou qualquer outra mudança de condição na linha de bombeamento, coluna CT ou no poço. Por esse motivo, o FIS foi projetado para gerar 2 saídas, uma chamada “Stator PDM” que certamente apontará para a alteração nos parâmetros resultante das condições do PDM (por exemplo, fresamento, parada, estator perdido no furo) e uma segunda saída chamada “Flow Restriction” que indica uma leitura de pressão anormal, mas não tem evidências suficientes para garantir que isso seja devido ao PDM.

A principal função de saída do FIS é o status de parada do motor, para o qual MF é mostrado na Figura 6. O mesmo formato MF é usado para a saída de restrição de fluxo.

3.6.1 PDM Status

O Status PDM foi gerado usando a função “automf” do skFuzzy que popula automaticamente a variável de saída com MFs igualmente distribuídos conforme a Figura 12. O universo de discurso foi de -1 a $+1$, onde o valor 0 (zero) é usado para denotar uma operação normal. Os valores linguísticos foram semelhantes às variáveis de entrada, exceto pela adição de mais 2 MFs, sendo então “EH” para “Extremamente Alto” e “EL” para “Extremamente Baixo”.


Os valores atribuídos para cada MF da variável de entrada estão na Tabela 4 juntamente com o significado de cada nível da saída. De acordo com o exemplo, se a saída de status do PDM resultar em H (alto), significa que o FIS inferirá que o PDM está fresando e funcionando conforme o esperado. Se a saída mudar para VH (Very High) infere-se que o motor está começando a travar ou está com uma velocidade de rotação menor que a ideal.

Tabela 4 - Funções de pertinência para variável PDM Status

PDM Status		Function Type	Limit Points			Desired Interpretation for this output
			A	B	C	
EH	Extremelly High	Triangular	0.66	1	1	Motor Plugged / Stalled
VH	Very High	Triangular	0.33	0.66	1	Motor low RPM / Stalling
H	High	Triangular	0	0.33	0.66	Motor milling
N	Normal	Triangular	-0.33	0	0.33	Motor working with no load
L	Low	Triangular	-0.66	-0.33	0	Motor pressure low
VL	Very Low	Triangular	-1	-0.66	-0.33	Motor pressure too low
EL	Extremelly Low	Triangular	-1	-1	-0.66	Rotor or BHA lost in hole

Fonte: Elaborado pelo Autor (2024).

Figura 10 – Descrição gráfica da variável PDM Status



Fonte: Elaborado pelo Autor (2024).

3.6.2 Flow Restriction

Da mesma forma, a saída Flow Restriction foi gerada usando a função “automf” (vista na Figura 13) e tendo exatamente os mesmos MFs da primeira. Apenas a interpretação de cada nível de saída é alterada como na Tabela 5, pois esta é a razão pela qual esta saída foi criada em primeiro lugar. Um valor de L (Baixo) nesta variável significa que o FIS inferiu que há um furo na coluna do TC ou um pequeno vazamento no sistema de bombeamento, enquanto que se mudar para VL (Muito Baixo) isso se deve a um problema mais crítico, pois


o BHA é desconectado da coluna CT e jogado dentro do poço, ou a coluna CT se separa e há uma pequena restrição ao fluxo.

Tabela 5 - Funções de pertinência para variável Flow Restriction

Flow Restriction		Function Type	Limit Points			Desired Interpretation for this output
			A	B	C	
EH	Extremelly High	Triangular	0.66	1	1	CT pipe or treating line clogged
VH	Very High	Triangular	0.33	0.66	1	CT BHA may be fully clogged
H	High	Triangular	0	0.33	0.66	CT BHA may be partially clogged
N	Normal	Triangular	-0.33	0	0.33	Normal restriction inside CT
L	Low	Triangular	-0.66	-0.33	0	Pin hole in CT string
VL	Very Low	Triangular	-1	-0.66	-0.33	BHA may be LIH or pipe parted
EL	Extremelly Low	Triangular	-1	-1	-0.66	Pipe or line parted on surface

Fonte: Elaborado pelo Autor (2024).

Figura 11 – Descrição gráfica da variável Flow Restriction



Fonte: Elaborado pelo Autor (2024).

3.7 BASE DE REGRAS

Após definir as funções de pertinência para as entradas e saídas do FIS, o próximo passo é definir as regras que definem os valores de saída do sistema de acordo com os valores das entradas. A base de regras foi então projetada com base no conhecimento de um especialista. A abordagem usual é definir pelo menos uma regra para cada combinação das entradas, o que resultaria em 125 regras na base de conhecimento. No entanto, uma análise preliminar dessas regras definiu que algumas combinações não poderiam definir um evento de estol, e, portanto, não teriam uma saída definida. Essas mesmas regras foram descartadas para a simplificação da base de regras.

A base de regras, ou tabela da verdade, é finalmente descrita na Tabela 6 para um total de 39 regras. Tomando a regra #12 como exemplo, se a entrada delta_CP for VH (Muito

Alto), o CP_deviation for H (Alto) e o CTW_deviation for L (Baixo), então o Status PDM produzirá VH (Muito Alto) e a Restrição de Fluxo produzirá N (Normal). Ao correlacionar com as Tabelas 4 e 5, o FIS inferirá que o PDM provavelmente está travando ou tem baixa velocidade de rotação e não há outra restrição de fluxo no sistema.

Tabela 6 - Base de regras do FIS

Rule	Inputs			Outputs	
#	delta_CP	CP_deviation	CTW_deviation	PDM Status	Flow Restriction
1	N	N	N or H or VH	N	N
2	VH	VH	N or H or VH	N	EH
3	VH	H	N or H or VH	N	VH
4	H	VH	N or H or VH	N	H
5	H	H	N or H or VH	N	H
6	L	L	N or H or VH	N	L
7	L	VL	N or H or VH	N	L
8	VL	L	N or H or VH	N	VL
9	VL	VL	N or H or VH	N	EL
10	VH	VH	L	EH	N
11	VH	H	L	VH	N
12	H	VH	L	VH	N
13	H	H	L	H	N
14	N	VH	L	H	N
15	N	H	L	N	N
16	L	L	L	L	N
17	L	VL	L	L	N
18	VL	L	L	VL	N
19	VL	VL	L	EL	N
20	VH	VH	VL	EH	N
21	VH	H	VL	EH	N
22	H	VH	VL	VH	N
23	H	H	VL	VH	N
24	N	VH	VL	H	N
25	N	H	VL	N	N
26	L	L	VL	L	N
27	L	VL	VL	L	N
28	VL	L	VL	VL	N
29	VL	VL	VL	EL	N
30	VH	N	L	VH	N
31	H	N	L	H	N
32	N	N	L	N	N
33	L	N	L	L	N
34	VL	N	L	VL	N
35	VH	N	VL	H	N
36	H	N	VL	H	N
37	N	N	VL	L	N
38	L	N	VL	VL	N
39	VL	N	VL	EL	N


Fonte: Elaborado pelo Autor (2024).

4 RESULTADOS

4.1 TESTE DO FIS

O FIS foi testado com os dados reais e as funções de pertinência de entrada e saída analisadas. Um exemplo das funções de pertinência com os dados de entrada e saída aplicado é apresentada a seguir. Os dados de entrada no ponto de aquisição analisado são: CP = 8252psi, WHP = 4902psi, CTW = 1668lbf. A figura 11 abaixo com as funções de entrada foi gerada pelo sistema.


Figura 12 - Funções de Pertinência de Entrada



Fonte: Elaborado pelo Autor (2024).

As funções de pertinência para as saídas também foram geradas e estão na figura 12 abaixo.

Figura 13 - Funções de Pertinência para as saídas



Fonte: Elaborado pelo Autor (2024).

Observa-se que a saída PDM Status indica a saída no valor de H (*High/Alto*) o que de acordo com a Tabela 4 - Funções de pertinência para variável PDM Status, indica que o PDM está em operação normal de fresamento, porém muito próximo ao limite de VH (*Very High/Muito Alto*) o que indica um possível estol do motor.

Já a saída Flow Restriction se encontra em nível normal, já que a mesma só se ativa caso haja um incremento de pressão que não possa ser associado a um evento de estol.

4.2 EXECUÇÃO DO FIS COM BASE DE DADOS

Dados reais de algumas operações com PDMs foram empregados para testar e verificar a funcionalidade do FIS proposto. A partir desses dados, um total de 4 conjuntos de dados foram selecionados para testar o FIS, chamados de: Pré-teste, Conjunto 1. Cada um deles foi analisado manualmente e os valores WHP_{sp}, W_{sp} e CP_{sp} para cada um dos conjuntos foram definidos.

Todos os conjuntos de dados foram executados no algoritmo FIS em Python 3.10 e os valores de saída registrados em uma planilha do Excel (formato.xlsx). O sistema analisou os dados ponto por ponto com uma velocidade média de 45 pontos analisados por segundo.

Os dados foram posteriormente plotados via Excel e anexados a esse trabalho para facilitar sua análise.

4.3 ANÁLISE DE RESULTADOS


Para todos os gráficos, linhas verticais na cor laranja foram sobrepostas indicando onde a saída do PDMStatus tinha um valor $\geq 0,5$, que é definido como VH (muito alto) ou EH (extremamente alto), e é onde o FIS inferiu que o evento de estol está sendo detectado. O mesmo foi feito para a saída FlowRestriction com linhas na cor vermelha.

Se durante 1s (ou 1 ponto de dado de aquisição) a saída do PDMStatus inferir VH ou EH, considera-se que ocorreu o estol do motor. Mesmo que a saída caia abaixo do limite de 0,5 logo após, apenas um ponto de detecção de estol poderia, em uma situação real, alarmar o operador em uma tela e ele/ela seria alertado sobre a condição anormal, juntamente com uma breve instrução na contingência a ser executada (por exemplo, parar o bombeio imediatamente).

4.3.1 Caso de pré-teste

Ao rodar esse conjunto através do FIS, obteve-se os dados exibidos na Figura 14, onde o FIS detectou corretamente todos os eventos de parada. As linhas verticais laranja na Figura 14 mostram os pontos de dados onde a saída do PDMStatus teve um valor $\geq 0,5$, que é definido como VH (Muito Alto) ou EH (Extremamente Alto) e é onde o FIS inferiu que o evento de parada está sendo detectado. A figura abaixo mostra os eventos de estol acontecendo ao redor. 09:43h, 09:54h e 09:57h. Olhando mais de perto, um pico de pressão pode ser visto por volta das 09:46h, que o sistema não sinalizou com sucesso como estol, pois não havia WOB aplicado para defini-lo como tal.

O FIS detectou corretamente 3 das 3 paradas presentes nestes dados.

Figura 14 - Gráfico para pontos de dados do caso de pré-teste e saídas do FIS

Fonte: Elaborado pelo Autor (2024).


4.3.2 Conjunto de dados 1

Nesse conjunto os eventos de parada foram detectados à medida que se formavam. Por volta das 03:01h (Figura 15), ocorre um evento que não foi detectado pelo sistema como estol. Isso ocorre porque o WOB não é alto o suficiente e a saída do PDMStatus não atingiu um valor superior a 0,5. Isso pode ser considerado normal, pois talvez o motor tenha começado a reduzir seu RPM; no entanto, a restrição tinha pouca robustez e foi removida pela broca antes que o WOB ou CP pudesse aumentar acima dos valores predefinidos.

Por volta das 06:00h, um evento FlowRestriction é detectado (indicado pela linha vertical vermelha) e isso pode ser devido ao fato de que o motor estava parado e, embora ainda tivesse pressão presa dentro do estator do motor, o operador começou a remover o WOB puxando o conjunto para cima, o que diminuiu o CTW_deviation de volta para N (Normal), e a saída FlowRestriction foi ativada. Esta ação de não esperar que a pressão reduza antes de mover a coluna de ferramentas é um erro operacional do lado do operador e pode resultar em rotação excessiva do PDM e, no pior dos casos, pode levar ao desenroscamento dos diferentes componentes do PDM e falha imediata da ferramenta. Em um cenário de caso real, a saída PDMStatus poderia ser conectada a um atuador na unidade CT que não permitiria que o tubo CT se movesse para cima mesmo se o operador operasse o *joystick* que controla o movimento do tubo.

O FIS detectou 7 das 8 paradas presentes nestes dados.

Figura 15 - Gráfico para pontos de dados do conjunto de dados 1 e saídas FIS




Fonte: Elaborado pelo Autor (2024).

4.3.3 Conjunto de dados 2

No conjunto de dados 2 (Figura 16), todos os pontos de estol às 23:19h, 23:29h e 00:15h foram detectados com sucesso.

Figura 16 - Gráfico para pontos de dados do conjunto de dados 2 e saídas FIS



Fonte: Elaborado pelo Autor (2024).

Por volta das 00:26h, houve um aumento de pressão que não resultou em uma saída positiva para PDM Status e mostra a importância de subtrair σ_{WHP} ao calcular $CP_deviation$ (σ_{CP}) como na Fórmula (6). Sem essa compensação, o sistema não contabilizaria o aumento do $CP_deviation$, pois, por ser decorrente do aumento do WHP, poderia acionar indevidamente uma das saídas e gerar uma falsa saída.


O FIS detectou 4 das 4 paradas presentes nestes dados.

4.3.4 Conjunto de dados 3

Ao executar o FIS com o último conjunto de dados (Figura 17), ocorrem alguns falsos alarmes durante a primeira metade da aquisição (antes das 21:06h), principalmente para a Restrição de Fluxo, que estava em constante alarme. Esses alarmes devem-se principalmente ao ponto de ajuste do CP definido como 7900psi, que é um valor preciso para a segunda metade da aquisição, mas não para a primeira metade, onde a pressão foi maior devido a uma vazão maior da bomba.

Isso indica que este FIS será mais preciso se também for ajustado pela vazão do fluido bombeado dentro da coluna do CT e através do PDM, o que não pôde ser feito devido à indisponibilidade de dados precisos da taxa da bomba em disponíveis dados. Durante a segunda metade da aquisição (21:06h em diante), o único evento de estol que ocorreu na realidade foi detectado com sucesso pelo FIS. Houve aumento de pressão às 21:14h; no entanto, esse evento não ativou o status do PDM, pois nenhum WOB foi aplicado e a saída de restrição de fluxo foi ativada conforme esperado.

Figura 17 - Gráfico para pontos de dados do conjunto de dados 3 e saídas FIS



Fonte: Elaborado pelo Autor (2024).

O FIS detectou 3 das 3 paradas presentes nestes dados.

4.4 DISCUSSÃO GERAL

No geral, o FIS detectou 17 dos 18 eventos de estol presentes nos dados, resultando em uma precisão de 94%, o que é considerado muito satisfatório. Como este sistema não é um controlador e não está conectado diretamente a nenhum atuador do processo, a figura do

operador humano estará sempre presente, e o FIS atuará de forma semelhante a uma segunda pessoa a todo momento observando os dados, e monitorando os trabalhos em conjunto com o operador.

Um total de 68.458 pontos de aquisição foram executados no sistema e sendo ponto referente espaçado em 1s (taxa de amostragem de 1Hz). A implementação Python deste FIS pode processar cerca de 30 pontos por segundo, o que se traduz em 33 milissegundos de tempo de processamento para cada 1s de dados, mostrando que o algoritmo é leve e pode ser portado para um dispositivo compacto e de baixo custo, como um FPGA (*Field Programmable Gate Array*), ou SBC (*Single Board Computer*).

O objetivo de construir um FIS usando Python e skFuzzy para detectar os stalls em uma operação de fresamento CT foi alcançado, e os objetivos deste trabalho foram atendidos. Usando os dados do mundo real disponíveis, essa abordagem pode ser validada, pois os eventos de parada presentes nesses dados foram sinalizados com sucesso pelo sistema como tal. Quase todos os eventos exceto 1 foram detectados, aferindo uma precisão de 94% para o sistema. Os eventos também foram detectados assim que a pressão de circulação começou a incrementar; portanto, em um cenário real, o objetivo de alertar o operador para agir antes que a parada se transforme em um dano permanente ao PDM seria alcançado.

Mesmo após descartar técnicas mais usuais baseadas em ML devido a restrições nos dados disponíveis, a abordagem FIS mais datada, com parâmetros e regras obtidos apenas pelo especialista, provou ser uma opção viável para resolver esse tipo de problema. Para mais problemas de nicho como o descrito neste artigo, onde não há grandes quantidades de dados disponíveis, as técnicas legadas de IA são provavelmente a única opção viável.

Durante esta pesquisa, nenhum trabalho semelhante foi encontrado durante a revisão da literatura. Isso não garante que nenhum sistema semelhante esteja sendo desenvolvido ou exista, pois tal sistema poderia fazer parte de um produto comercial de uma empresa privada e, portanto, não ser apresentado em um artigo para a comunidade científica devido a necessidades comerciais.

5 CONSIDERAÇÕES FINAIS

O objetivo de construir um FIS usando Python e skFuzzy para detectar os stalls em uma operação de fresamento CT foi alcançado, e os objetivos deste trabalho foram atendidos. Usando os dados do mundo real disponíveis, essa abordagem pode ser validada, pois os eventos de parada presentes nesses dados foram sinalizados com sucesso pelo sistema como tal com uma precisão de 94%. Com especial atenção ao fato dos eventos serem detectados durante os primeiros segundos do aumento da pressão de circulação, indicando que em um cenário real, o objetivo de alertar o operador para agir antes que o estol se transforme em um dano permanente ao PDM poderia ser alcançado.

REFERÊNCIAS

ANYANWU, O.N.; KLOTZ, C.; LABRECQUE, D.; ULRICH, C. Optimized downhole mud motor delivers outstanding performance improvement in Alaska coiled tubing drilling. *In: SPE/ICoTA COILED TUBING & WELL INTERVENTION CONFERENCE AND EXHIBITION*, 2012, The Woodlands. **Proceedings** [...]. The Woodlands: SPE International, mar. 2012. Disponível em: <https://doi.org/10.2118/153474-MS>. Acesso em: 16 jun. 2025.

BARROS, L. C.; FERNANDES, V. F. **Introdução à teoria Fuzzy**. Campinas: UNICAMP, 2019.

BELLO, O.; OPPELT, J.; HOLZMANN, J.; OBIWANNE, A. Application of artificial intelligence techniques in drilling system design and operations: a state of the art review and future research pathways: Artificial Intelligence (AI) oil and gas industry drilling prediction diagnosis wel. *In: SPE NIGERIA ANNUAL INTERNATIONAL CONFERENCE AND EXHIBITION*, 2016, Lagos. **Proceedings** [...]. Lagos: Society of Petroleum Engineers, aug. 2016. Disponível em: <https://doi.org/10.2118/184320-MS>. Acesso em: 16 jun. 2025.

CHEN, X.; GAO, D.; GUO, B.; FENG, Y. Real-time optimization of drilling parameters based on mechanical specific energy for rotating drilling with positive displacement motor in the hard formation. **Journal of Natural Gas Science and Engineering**, Philadelphia, v. 35, p. 686–694, 2016. Disponível em: <https://doi.org/10.1016/j.jngse.2016.09.019>. Acesso em: 25 maio 2025.

COSTA, A.; RODRIGUEZ, A.G.; SIMAS, E.P.L.; ARAUJO, R.S. **Lógica fuzzy: conceitos e aplicações**. Porto Alegre: UNISINOS, abr. 2005.

CAI, L.Y.; KWAN, H.K. Fuzzy classifications using fuzzy inference networks. **IEEE Transactions on Systems, man, and cybernetics: part B**, New Jersey, v. 28, n. 3, p. 334 - 347, 1998. Disponível em: <https://doi.org/10.1109/3477.678627>. Acesso em : 25 maio 2025.

CRAIG, S.; HARRIS, J.; LEHR, D.; BRANDT, N. Best practices for composite plug milling. *In: SPE/ICOTA COILED TUBING & WELL INTERVENTION CONFERENCE AND EXHIBITION*, 2012, The Woodlands. **Proceedings** [...]. The Woodlands: SPE International, 2012. p. 225-240. Disponível em: <https://doi.org/10.2118/154060-ms>. Acesso em: 25 maio 2025

DEMIRER, N.; ZALLUHOGLU, U.; MARCK, J.; DARBE, R. Automated steering with real-time model-based control. *In: INTERNATIONAL PETROLEUM TECHNOLOGY CONFERENCE*, 2020, Dhahran. **Proceedings** [...]. Dhahran: IPTC, 2020. Disponível em: <https://doi.org/10.2523/IPTC-19817-MS>. Acesso em: 16 jun. 2025.

FENG, G. A survey on analysis and design of model-based fuzzy control systems. **IEEE Transactions on Fuzzy Systems**, New Jersey, v. 14, p. 676 - 697, 2006. Disponível em: <https://doi.org/10.1109/TFUZZ.2006.883415>. Acesso em: 25 maio 2025.

JÚNIOR, I.; NOVAKOWSKI, S. **Lógica fuzzy sistemas de apoio à decisão**. Porto Alegre: UNISINOS, 2005.

KAHRAMAN, C. **Fuzzy multicriteria decision making: theory and applications with recent developments**. Turkey: Springer Science, 2008.

KAMYAB, M.; YALAMARTY, S.S.; ROGERS, P.; CHEATHAM, C. Automated procedural compliance drives real time drilling optimization. *In: SPE/IADC DRILLING CONFERENCE PROCEDURE*, 2020, Galveston. **Proceedings** [...]. Galveston: [s/n], 2020.

LIMA JÚNIOR, F. R.; CARPINETTI, L. C. R. Uma comparação entre os métodos Topsis e Fuzzy no apoio à tomada de decisão multicritério para seleção de fornecedores. **Gestão e Produção**, São Carlos, v. 22, n.1, 2015. Disponível em: <https://www.scielo.br/j/gp/a/YYQS49M7kYZGVG8sgcKxJHC/?lang=pt>. Acesso em: 16 jun. 2025.

MA, T.; CHEN, P.; ZHAO, J. Overview on vertical and directional drilling technologies for the exploration and exploitation of deep petroleum resources. **Geomechanics and Geophysics for Geo-Energy and Geo-Resources**, Heidelberg, v. 2, p. 365–395, 2016. Disponível em: <https://doi.org/10.1007/s40948-016-0038-y>. Acesso em: 25 maio 2025.

NOSHI, C.I.; SCHUBERT, J.J. The role of machine learning in drilling operations: a review. *In: SPE Eastern Regional Meeting*, 2018, Pittsburgh. **Proceedings** [...]. Pittsburgh: SPE International, 2018. p. 7–11. Disponível em: <https://doi.org/10.2118/191823-18erm-ms>. Acesso em: 25 maio 2025

MAMDANI, E. H.; ASSILIANO, S. Um experimento em síntese linguística com um controlador de lógica difusa. *International Journal of Man-Machine studies*, London, v. 7, n. 1, p. 1-13, 1975.

POSSELT, E. L. **Aplicação embarcada não intrusiva de classificação de condutores**. Santa Cruz do Sul, UNISC, 2008. Trabalho apresentado. Tudo que não é apresentado deve ser colocado em nota de rodapé e tirar da referência. Só se referencia o que é publicado. Há outros trabalhos assim aqui nas referências.

QURAT-UL, A.; IQBAL, S.; KHAN, S.A.; MALIK, A.W.; AHMAD, I.; JAVAID, N. IoT operating system based fuzzy inference system for home energy management system in smart buildings. **Sensors**, Basel, v. 18, n. 9, p. 2802, 2018. Disponível em: <https://doi.org/10.3390/s18092802>. Acesso em: 25 maio 2025.

REZENDE, S.O. Sistemas inteligentes fundamentos e aplicações. *In: ALMEIDA, P. E. M.; EVSUKOFF, A. G. (org.). Sistemas Fuzzy*. São Paulo: Manole, 2003. p.169-201.

SELVIK, J.T.; BELLAMY, L. J. Addressing human error when collecting failure cause information in the oil and gas industry: a review of ISO 14224:2016. **Reliability Engineering & System Safety**, London, v. 194, 106418, Feb. 2018. Disponível em: <https://doi.org/10.1016/j.ress.2019.03.025>. Acesso em: 25 maio 2025

SIRCAR, A.; YADAV, K.; RAYAVARAPU, K.; BIST, N.; OZA, H. Application of machine learning and artificial intelligence in oil and gas industry. **Petroleum Research**,

Beijing, v. 6, n. 4, p. 379 - 391, 2021. Disponível em:
<https://doi.org/10.1016/j.ptlrs.2021.05.009>. Acesso em: 25 maio 2025.

SOLANKI, P.; BALDANIYA, D.; JOGANI, D.; CHAUDHARY, B.; SHAH, M.; KSHIRSAGAR, A. Artificial intelligence: new age of transformation in petroleum upstream. **Petroleum Research**, Beijing, v. 7, n. 1, p. 106–114, 2022. Disponível em: <https://doi.org/10.1016/j.ptlrs.2021.07.002>. Acesso em: 25 maio 2025.

SOUZA, O. N.; MESQUITA, M. E. R. **Introdução à teoria dos conjuntos Fuzzy**. Londrina, Universidade Estadual de Londrina. 2010.

STHEOPHILUS, C.; ESENOWO, V. N.; AREWA, A. O.; IFELEBUEGU, A. O.; NNADI, E. O.; MBANASO, F. U. Human factors analysis and classification system for the oil and gas industry (HFACS-OGI). **Reliability Engineering & System Safety**, London, v. 167, p. 168–176, 2017. Disponível em: <https://doi.org/10.1016/j.ress.2017.05.036>. Acesso em: 25 maio 2025.

TAKAGI, T.; SUGENO, M. Fuzzy Identification of systems and its applications modeling and control. **IEEE Transactions on Systems, man, and cybernetics**, New Jersey, v. 15, n.1, p. 116–132, 1985. Disponível em:
https://www.scss.tcd.ie/khurshid.ahmad/Teaching/Lectures_on_Fuzzy_Logic/Takagi%20Sugeno%20Modelling.pdf. Acesso em: 25 maio 2025.

TANSCHKEIT, R. **Sistemas Fuzzy**. Rio de Janeiro: DEE-PUC-Rio, 2023. Disponível em: <http://www.ica.ele.puc-rio.br/sistema-fuzzy>. Acesso em: 28 mar. 2023.

ZADEH, L.A. Fuzzy sets. **Information and Control**, Maryland Heights, v. 8, n. 3, p. 338-353, 1995. Disponível em: [https://doi.org/10.1016/S0019-9958\(65\)90241-X](https://doi.org/10.1016/S0019-9958(65)90241-X). Acesso em: 25 maio 2025.

ZHANG, Z.; SHEN, Y.; CHEN, W.; CHEN, Z. Analyzing energy and efficiency of drilling system with mud motor through big data. In: SPE ANNUAL TECHNICAL CONFERENCE AND EXHIBITION, 2020, Virtual. **Proceedings** [...]. Houston: SPE International, 2020.

ZHAO, Y.; ZALLUHOGLU, U.; MARCK, J.; DEMIRER, N.; MORARI, M. Model predictive control for mud motor operation in directional drilling. In: AMERICAN CONTROL CONFERENCE, 2019, Philadelphia. **Proceedings** [...]. Philadelphia, 2019. p. 5197–5202. Disponível em: <https://doi.org/10.23919/acc.2019.8815289>. Acesso em: 25 maio 2025

ZIMMERMANN, H.J. **Fuzzy set theory and its applications**. Massachussets: Kluwer Academic, 1991.