

Monitoramento da Produção Enxuta com Inteligência Artificial^{*}

Fábio Muniz Mazzoni^{*} André da Silva Barcelos^{**}

^{*} Departamento de Engenharia de Produção e Sistemas Computacionais, Universidade Federal Fluminense - UFF, RJ, (e-mail: fabiomuma@hotmail.com).

^{**} Departamento de Engenharia Eletrotécnica e de Computadores, Universidade Beira Interior - UBI, Covilhã, PT (e-mail:andrebarcelos813@hotmail.com)

Abstract: The liquefied petroleum gas (LPG) production industry, commercially known as residential gas, presents challenges such as continuous production, the need to control the production process in real time and the variability of product quality due to the behavior of parameters thermodynamics of production. In this scenario, this work presents two distinct algorithms and proposes methods to monitor the quality of LPG in real time. At the end, an analysis tool and the control measures that must be implemented will be presented to guarantee the reduction of variability according to the principles of lean production.

Resumo: A indústria de produção de gás liquefeito de petróleo (GLP), comercialmente denominado como gás de cozinha, apresenta desafios como a produção contínua, a necessidade do controle de processo de produção em tempo real e a variabilidade da qualidade do produto devido ao comportamento dos parâmetros termodinâmicos da produção. Neste cenário, este trabalho apresenta dois algoritmos distintos e propõe métodos para monitorar a qualidade do GLP em tempo real. Ao final será apresentado uma ferramenta de análise e as medidas de controle que devem ser implementadas para garantir a redução da variabilidade de acordo com os princípios de produção enxuta.

Keywords: Artificial Intelligence; Lean Manufacturing Indexation; Variability Analysis; Optimization; Liquefied Petroleum Gas.

Palavras-chaves: Inteligência Artificial; Análise de Variabilidade; Indexação da Produção Enxuta; Otimização; Gás Liquefeito de Petróleo.

1. INTRODUÇÃO

A produção enxuta tem por objetivo atender a demanda dos consumidores com qualidade e menor desperdício possível de insumos e recursos. Para isto, faz-se necessário que o suprimento de insumos e serviços encontrem-se em sincronia com a demanda. Os princípios *lean* e *just-in-time* representam uma ruptura da prática tradicional das operações e tornaram-se amplamente aceitas para promover a sincronização dos processos (Slack et al., 2013). Uma das causas da interrupção do processo da produção enxuta é o aumento da variabilidade dos parâmetros do processo que devem ser monitorados e controlados (Sanders et al., 2016).

Outra forma de considerar a produção enxuta é propor a redução da variabilidade, trabalhar em fluxo e puxar a produção (Womack and Jones, 2017). A redução da variabilidade tem por objetivo proporcionar o início do processo de produção enxuta, entre a demanda e a produção puxada que deve ser monitorada constantemente a fim de manter

o controle e o planejamento com visão de longo prazo (Marodin et al., 2018).

É possível aplicar estes conceitos em unidades de processamento de gás natural (UPGN), que são instalações industriais com a finalidade de produzir derivados do gás natural. Um dos derivados mais conhecidos é o gás liquefeito de petróleo (GLP), comercialmente denominado gás de cozinha, que é formado predominantemente por propano (C_3H_8) e butano (C_4H_{10}) (Bakosova et al., 2017). Assim, as UPGNs realizam a desidratação do gás natural para um posterior fracionamento em uma torre debutanizadora, com intuito de produzir derivados como o GLP, o gás residual e a gasolina natural (Thomas et al., 2004).

A torre debutanizadora é utilizada para fracionar o insumo (gás natural), por meio do controle e otimização dos parâmetros termodinâmicos. Por conseguinte, é necessário evitar a presença de compostos com peso molecular maiores que o butano, com a finalidade de garantir a especificação do GLP. Com este viés, a Agência Nacional do Petróleo (ANP), especifica ensaios para garantir a qualidade do GLP, onde o mais importante e largamente utilizado na indústria é o que mede o resíduo volátil do ponto de ebulição,

^{*} Agradecemos à Petrobras Transporte S.A pelo apoio técnico-científico deste projeto.

que comercialmente é denominado ensaio de intemperismo (Panapakidis and Dagoumas, 2017).

O intemperismo é definido nas normas da Associação Brasileira de Normas Técnicas (ABNT), como a temperatura resultante da evaporação atmosférica de 95% do volume de GLP. O ensaio de intemperismo considera que o GLP está enquadrado nas especificações legais, e disponível para a comercialização quando da evaporação do GLP, resultar um resíduo de 5% do volume inicial em uma temperatura de até 2,2°C (Silva et al., 2017).

A presença de resíduos acima de 5%, é denominado desenquadrado nas especificações legais e por conseguinte, onde a presença de compostos de peso moleculares maiores que o butano exercem forte influência ao desenquadramento do intemperismo (Diehl et al., 2018). Uma vez que ocorra o desenquadramento do produto, este poderá ser reprocessado ou descartado, o que caracteriza perda de insumo, desperdício e retrabalho (Bahadori, 2014).

2. OBJETIVO

Este trabalho tem por objetivo desenvolver uma ferramenta baseada em inteligência artificial, que identifique e monitore a tendência e a variabilidade do intemperismo do GLP em uma planta industrial, com a finalidade de minimizar o reprocessamento ou desperdício na produção de GLP desenquadrado de uma UPGN.

3. A PRODUÇÃO DE GLP

3.1 O Processo de Debutanização

A torre debutanizadora realiza o fracionamento de hidrocarbonetos que constituem o gás natural, onde separa etano (C_2), propano (C_3), butano (C_4) e pentanos (C_5+), por diferença de pressão parcial, peso molecular e volatilidade. Uma maneira de realizar o fracionamento é controlar a pressão de topo, a temperatura de fundo e a vazão de refluxo, que alteram diretamente os parâmetros termodinâmicos da torre (Kidnay et al., 2019).

O diagrama da torre debutanizadora está ilustrado na Figura 1, onde se observa que a entrada de carga da torre debutanizadora consiste de hidrocarbonetos para o fracionamento. A corrente de fundo desta torre, consiste de um subproduto de pentanos C_5 , denominado gasolina natural, que possui baixa concentração de C_4 e C_3 (Sayed et al., 2017).

Por outro lado, o produto que ascende do interior ao topo da torre é C_4 e C_3 , e uma concentração de C_2 que possibilita o enquadramento do GLP (Kidnay et al., 2019). Este enquadramento deve atender às especificações físico-químicas estabelecidas pelos órgão reguladores, portanto, a ANP é o órgão governamental responsável por determinar as especificações mínimas, para garantir a qualidade do produto final de Almeida et al. (2016).

Na topo da torre debutanizadora monitora-se a temperatura e a pressão do produto em ascensão. Deste modo, observa-se o vaso de refluxo que possui GLP em duas fases. Assim, utiliza-se deste vaso para monitorar a qualidade do GLP e verificar a ocorrência de ascensão indevida de C_5

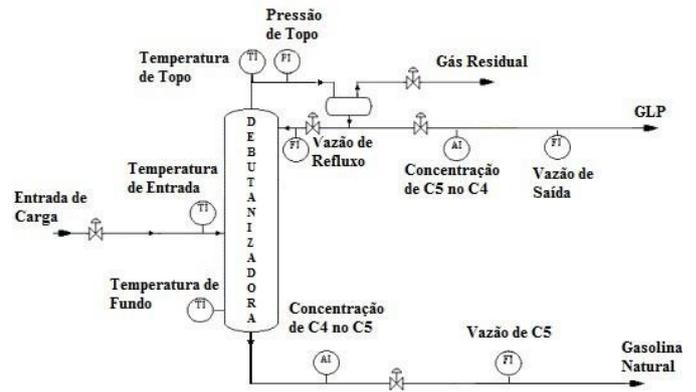


Figura 1. Diagrama da Torre Debutanizadora

proveniente do interior da torre. Na ocorrência de desconexão operacional e por conseguinte, de ascensão indevida de C_5 , é possível recircular este produto para o interior da torre. Isto se dá por meio de bombas centrífugas, que possuem a finalidade de garantir o intemperismo do GLP, evitando a contaminação por pentanos (Kidnay et al., 2019).

Outrossim, o refluxo possui a função de controlar a pressão interna da torre e a temperatura de topo. Por conseguinte, uma vazão de refluxo mínima é exigida, pois é necessário manter os parâmetros do fracionamento controlados sob o viés termodinâmico. (Sayed et al., 2017).

3.2 Parâmetros do Processo

Conforme verificado na Figura 1, são necessários instrumentos e sensores apropriados conforme a Tabela 1. O controle destas variáveis está baseado nas curvas de equilíbrio de fases líquido-gás dos hidrocarbonetos. Assim, o conhecimento prévio das curvas de equilíbrio e dos parâmetros termodinâmicos da torre, permitem construir um sistema inteligente que monitore a tendência do processo (Diehl et al., 2018).

Tabela 1. Parâmetros do Processo

Parâmetro	Unidade	Faixa de Medida
Pressão de Topo	kgf/cm ²	11-15
Vazão de Refluxo	m ³ /h	120-260
Vazão de Saída	m ³ /h	20-50
Temperatura de Topo	°C	200-280
Temperatura de Entrada	°C	120-180
Temperatura de Fundo	°C	220-320
Vazão de C_5	m ³ /h	30-60
Concentração de C_4 no C_5	-	0-15
Concentração de C_5 no C_4	-	0-5

Uma abordagem para construir um sistema inteligente de monitoramento, é definir um ponto de comportamento no espaço n-dimensional que representa os parâmetros da torre debutanizadora. Estes parâmetros são controlados para situar-se na região de enquadramento e otimização do intemperismo, possibilitando a produção enxuta (Bakosova et al., 2017). A tendência da variação do comportamento para uma região desenquadrada do GLP, deve ser prevista pelos algoritmos de inteligência artificial, com a finalidade de auxiliar a tomada de decisão. (Panapakidis and Dagoumas, 2017).

Assim, a função de comportamento $f(x)$, é definida como uma sêtucla que equaciona a pressão de topo (Pt), vazão de refluxo (Qr), temperatura de topo (Tt), temperatura de entrada (Te), temperatura de fundo (Tf), concentração de C_4 no C_5 (K45) e concentração de C_5 no C_4 (K54) conforme Equação 1.

$$y = f(Pt; Qr; Tt; Te; Tf; QC4; K45; K54) \quad (1)$$

Ao computar a função de comportamento, obtém-se um ponto em 7 dimensões e assim, ao verificar a variação do comportamento da torre debutanizadora, será obtido duas regiões do espaço que são relativas ao enquadramento do GLP e o desenquadramento. Vale ressaltar que a região de enquadramento, está necessariamente contida na região de desenquadramento.

3.3 O Controle do Processo

Para validar o enquadramento do GLP é realizado um ensaio de intemperismo, que consiste na análise do produto de topo a cada 2 horas, de acordo com as características de cada planta de processamento (de Almeida et al., 2016). A instabilidade do processo altera a função de comportamento, que tende para regiões que caracterizam o desenquadramento do GLP. (Jin and Lim, 2019).

Outrossim, o sistema de controle altera a função de comportamento de acordo com o intemperismo, que é realizado por meio de ensaios (Fatima et al., 2019). Isto significa que a tomada de decisão do sistema de controle ocorre em tempo-real, porém é necessário aguardar o ensaio de intemperismo para validação das ações de controle. Portanto, por motivos diretos, esta abordagem inviabiliza a otimização da produção, pois trata-se de um processo dinâmico com validação insuficiente (Bakosova et al., 2017).

4. FERRAMENTAS DE ANÁLISE

Este artigo propõe o desenvolvimento de dois algoritmos, que servem de base para uma ferramenta de monitoração da análise da variabilidade do processo de debutanização, que estão descritas nas subseções seguintes. Para o desenvolvimento desta ferramenta, inicialmente é criada uma base de dados real, composta por 1000 amostras de comportamento sem rótulos de classe.

O simulador de processo CHEMSEPTM é capaz de classificar as amostras de comportamento do processo em enquadramento ou desenquadrado, conforme a variação dos parâmetros da função comportamento (Tgarguifa et al., 2017). Com este viés, a base de dados passa a conter instâncias com duas regiões distintas e corretamente classificadas por meio dos modelos termodinâmicos do simulador, que serão utilizadas na etapa de treinamento dos algoritmos (Zhou et al., 2019).

Após a etapa de treinamento, os algoritmos devem ser capazes de identificar as entradas e em seguida atualizarem-se. Para esta simulação, foram utilizadas outras 400 instâncias distintas para validação e 400 para teste. A determinação da quantidade de amostras de comportamento deve-se ao fato de que a aquisição dos dados, a computação

e apresentação dos resultados pelo CHEMSEP, com posterior treinamento dos algoritmos, duram aproximadamente 2 horas de computação com validação cruzada.

4.1 Rede Bayesiana

A teoria probabilística de Naive Bayes permite desenvolver classificadores Gaussianos à partir da premissa de independência linear entre as variáveis aleatórias. (Martin et al., 2017). Neste caso, o algoritmo calcula a probabilidade condicional das instâncias e realiza estimativa que determina quais os grupos que cada instância deve pertencer (Witten et al., 2017).

A Equação 2 expressa a probabilidade condicional de uma variável aleatória x pertencer a uma classe y , com distribuição de probabilidade $P(y)$. A probabilidade $P(x|y)$ é uma observação condicional da variável aleatória x na classe y , enquanto o denominador é um produto normalizador que realiza um somatório de probabilidades condicionais em todas as classes y' com probabilidade $P(y')$.

$$P(y|x) = \frac{P(x|y)P(y)}{\sum_{y'} P(x|y')P(y')} \quad (2)$$

Por conseguinte, é possível obter a probabilidade que cada variável aleatória x_i adquiere, à partir da observação de uma determinada classe y . Neste caso esta afirmação está expressa na Equação 3, que resume no lado direito da igualdade, o produto de probabilidades condicionais de todas as variáveis aleatórias x_i à partir da observação de uma classe y .

$$P(x_1, x_2, \dots, x_d|y) = \prod_{i=1}^d P(x_i|y) \quad (3)$$

Ao assumir que cada variável aleatória x_i possui uma distribuição de probabilidades gaussiana em um suporte no domínio \mathbb{R} , por indução, estas variáveis possuem média μ_i e variância σ_i definidas. Neste caso, o produto vetorial entre cada suporte resulta em um limite de decisão que assume a forma de sino em i dimensões.

Este trabalho possui duas classes de decisão em função de sete variáveis aleatórias conforme a Equação 1. Neste caso as variáveis serão normalizadas no intervalo fechado entre 0 e 1, porém é esperado que as médias e as variâncias destas variáveis sejam distintas entre si. Isto significa que a superfície resultante do produto vetorial de $i = 7$ suportes é uma curva parabólica genérica com caudas gaussianas.

Assim, as redes Bayesianas irão convergir para estruturas médias, à medida que novas amostras são fornecidas durante a etapa de treinamento (Saritas and Yasar, 2019). O custo computacional é um fator preponderante neste algoritmo, pois é necessário atualizar a probabilidade condicional a cada nova entrada (Tsangaratos and Ilia, 2016).

Ao final do treinamento, é fornecido um conjunto de instâncias que devem validar a superfície de decisão. Por fim, problemas computacionais que envolvem a atribuição de valor zero a uma probabilidade é solucionado com a suavização de Laplace, que adiciona um número ε a cada classe.

Por definição é necessário assumir que as distribuições das variáveis aleatórias são independentes, e sendo assim, problemas que envolvem dados correlacionados impedem a acurácia do algoritmo. Contudo, neste trabalho a temperatura de fundo (Tf), a temperatura de entrada (Tf), a vazão de refluxo (Qr) e a concentração de C_4 no C_5 (K45) são linearmente independentes entre si.

4.2 Máquina de Vetor de Suporte

Uma máquina de vetor de suporte cria hiperplanos de separação com complexidade ajustável e desta forma, este algoritmo pode ser utilizado como um classificador multivariável ou identificador de *outliers* (Scholkopf and Smola, 2018). A utilização de um *kernel*, que promove alterações nos hiperplanos de separação ou a adaptação de uma suavização das margens, permitem que a máquina de vetor de suporte encontre hiperplanos de separação, por meio de uma transformação não-linear de um espaço de alta dimensionalidade (Huang et al., 2018).

Em síntese máquina de vetor de suporte é um algoritmo que constrói hiperplanos de separação, em função de um vector de pesos w_o (Haykin, 2007). Em uma amostra de tamanho N , com variáveis x_i de rótulo d_i , é viável estabelecer o problema de otimização por meio dos multiplicadores de Lagrange l_i , que maximizam a função objectivo da Equação 4.

$$\begin{aligned} \max \quad & \sum_{i=1}^N l_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N l_i l_j d_i d_j x_i^T x_j \\ \text{subject to a} \quad & \sum_{i=1}^N l_i d_i = 0 \\ & 0 \leq l_i \leq C \end{aligned} \quad (4)$$

Os vectores de peso ótimos w_o e o bias são calculados de acordo com as Equações 5 e 6.

$$w_o = \sum_{i=1}^N l_i d_i x_i \quad (5)$$

$$b_o = 1 - w_o^T x_i \quad \text{iff} \quad d_i = 1 \quad (6)$$

O kernel $x_i^T x_j$ da Equação 4, pode ser substituído por um produto de funções $k(x, x')$. Para isto, é suficiente e necessário que $k(x, x')$ seja simétrico, contínuo, possua autofunções $\phi(x)$ e $\phi(x')$ de autovalores positivos e atenda as restrições de Mercer, que estão descritas nas Equações 7 e 8.

$$\int_b^a \int_b^a k(x, x') \phi(x) \phi(x') dx dx' \geq 0 \quad (7)$$

$$\int_b^a \phi(x)^2 dx < \infty \quad (8)$$

Ao supor que k_1 e k_2 sejam kernels distintos, as propriedades a seguir são válidas. Isto permite interpretar que uma máquina de vetor de suporte, é um algoritmo de separação e classificação por kernels (Haykin, 2007).

$$k(x, x') = \alpha k_1(x, x') + \beta k_2(x, x') \quad \text{for} \quad \alpha, \beta \geq 0 \quad (9)$$

$$k(x, x') = \exp\left(\frac{-\|x - x'\|^2}{\sigma^2}\right) \quad (10)$$

4.3 Análise de Variabilidade

A análise da variabilidade da concentração de pentanos (C_5) no produto de topo K54, caracteriza a qualidade do GLP em relação ao ensaio de intemperismo. A redução da variabilidade deste parâmetro é fundamental para a manutenção da qualidade do produto e portanto, deve ser monitorada e controlada. (Loehlin and Beaujean, 2016).

As técnicas desenvolvidas para a garantia da otimização do processamento foram as Curvas de Média Móvel Acumuladas, para determinar os pontos de tomada de decisão com intuito de prever o intemperismo e as Curvas de Desvio Padrão Acumulado, que deve medir a variabilidade do processo, a fim de garantir a qualidade do GLP e atender as diretrizes da produção enxuta (Womack and Jones, 2017).

Assim, como os algoritmos aprendem a classificação binária, é necessário uma adaptação que possibilite monitorar a tendência da classificação após a rede treinada. No algoritmo de Bayes é inserido uma função acumulativa que monitora a tendência de cada nova instância, sem que seja realizada uma nova atualização das funções de distribuição condicional. Com isto é possível verificar a direção de novas instâncias em uma rede passada e após um intervalo de tempo onde não acontece o desenquadrado, atualiza-se toda a rede (Faris et al., 2016).

Para a SVM, a ideia é basicamente a mesma, ao computar a variação do total de atualizações das margens de separação é verificado a tendência do comportamento, que deve reduzir ou ampliar a região de classificação correta (Scholkopf and Smola, 2018).

5. EXPERIMENTOS E RESULTADOS

A configuração das redes de Bayes é iniciada pela determinação das funções de densidade de probabilidade de cada variável aleatória da Eq. 1. Ao assumir que estas funções estão descorrelacionadas, inicia-se a etapa de treinamento que define as regiões de classificação. A MVS utiliza o kernel gaussiano conforme Eq. 10, que é escalonado iterativamente pela Eq. 9, onde o parâmetro α é iniciado em 1 e o parâmetro β em 0. As margens são mantidas rígidas com regularização Lasso.

Na etapa de testes, considera-se acerto de classificação, quando o ponto de comportamento (instância) é classificado como enquadrado e necessariamente, esta classificação está correta (AE). Por conseguinte, também será uma classificação correta, quando a instância é classificada como desenquadrado e necessariamente este ponto de comportamento é desenquadrado (AD).

O erro de classificação pelo algoritmo acontece quando a instância é classificada como enquadrada e definitivamente a instância é desenquadrado (EE). Na mesma ideia, quando a instância é classificada como desenquadrado e necessariamente o ponto de comportamento é enquadrado (ED), ocorre um erro de classificação.

A validação utiliza 400 amostras, e os resultados obtidos para algoritmo estão na Tabela 2, onde se utiliza da validação cruzada para assegurar a generalização do modelo em relação à classificação.

Tabela 2. Resultados da validação

Algoritmo	AE	AD	EE	ED	Acurácia(%)
Bayes	190	189	12	9	94.45
Bayes CV	191	190	11	8	95.01
MVS	200	198	2	0	99.49
MVS CV	199	198	2	1	99.24

A acurácia relativamente inferior das redes de Bayes em relação a MVS, é devido à necessidade de assumir que os dados estão descorrelacionados, para posteriormente construir a rede. Ainda assim, essas redes de Bayes apresentam acurácia suficiente, com controle de *overfitting* pela validação cruzada.

Na Figura 2, em azul encontra-se o monitoramento do intemperismo e o desenquadramento. A curva de decisão em laranja traz a informação de tendência ao desenquadramento, monitorada pela rede de Bayes, onde o ponto em que é necessário uma tomada de decisão está determinado de forma antecipada, pela interseção da respectiva curva com o eixo do intemperismo. A curva em cinza, denominada curva de contingência, realiza o mesmo procedimento para a máquina de vetor de suporte.

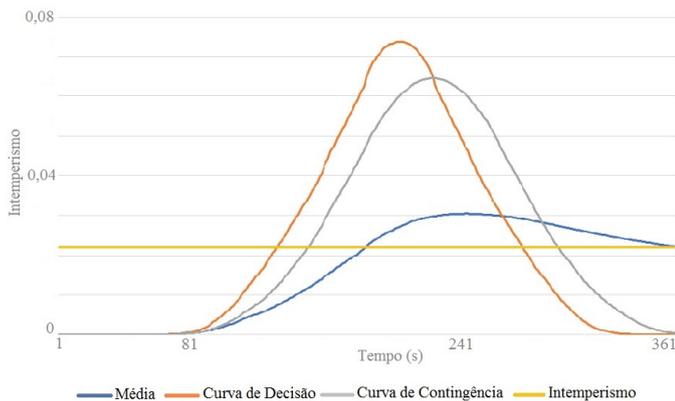


Figura 2. Curva de Média Móvel sem Alteração de Parâmetros do Processo

Na Figura 3 as curvas apresentam o intemperismo devidamente controlado, por meio de alterações produzidas no simulador. Neste caso, realizou-se o aumento da vazão de refluxo, quando a curva em laranja cruzou o eixo do intemperismo em amarelo. Entende-se que, diferentes decisões aplicadas à outros parâmetros poderiam alterar, de mesma maneira o comportamento do intemperismo, porém a devida atuação surtiu o efeito necessário para garantir o enquadramento do GLP e a estabilidade da produção.

Observa-se em outra simulação a caracterização do aumento da variabilidade da composição da produção, esta variabilidade também possui a capacidade de desencadear o processo de desenquadramento do GLP. A Figura 4, permite observar que o aumento da variabilidade aconteceu em média constante e a curva de decisão, em laranja prevê o aumento da variabilidade. Nesta figura, nenhuma medida de controle foi adotada e a variabilidade do processo permitiu o desenquadramento do GLP.

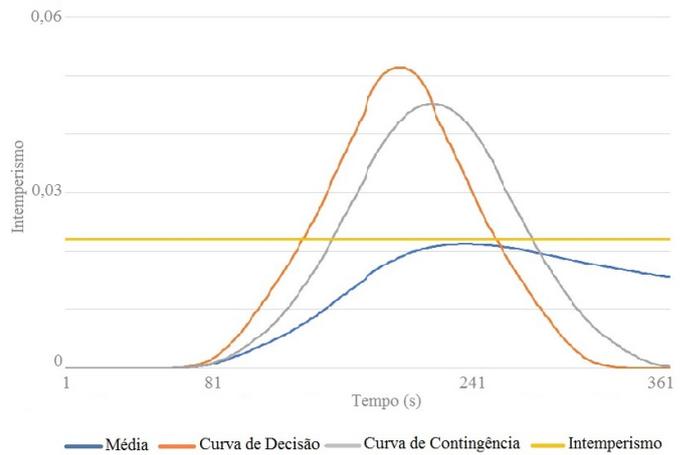


Figura 3. Curvas de Média Móvel com Alteração de Parâmetros da Produção

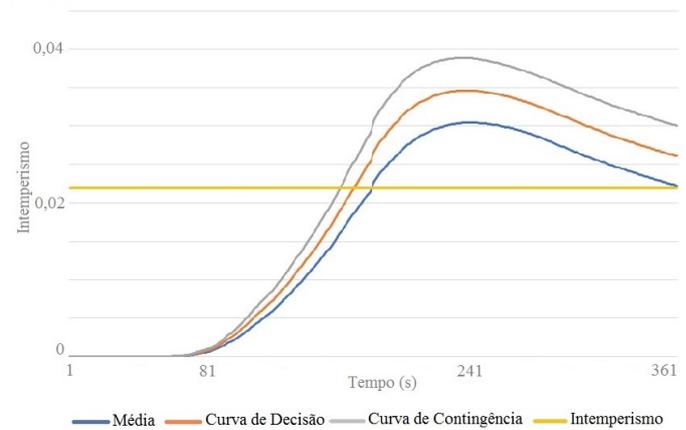


Figura 4. Curvas de Desvio Padrão sem Alteração de Parâmetros da Produção

Por fim, em uma outra simulação utilizando os mesmos dados para o desenvolvimento da Figura 4, fez-se uso de uma tomada de decisão, aumentando o refluxo da torre simulada quando a curva em laranja cruzou o eixo do intemperismo e o resultado desta ação está representado na curva nas curvas da Figura 5, onde foi possível o comportamento e atuar nos parâmetros do processo impedindo o desenquadramento do GLP.

6. CONCLUSÕES

Este trabalho desenvolve dois algoritmos e uma ferramenta para a análise da variabilidade, com intuito de auxiliar a tomada de decisão no fracionamento de gás natural e produção de GLP. Os algoritmos e a análise da variabilidade apontam a tendência dos parâmetros do processo e assim, permite que o controle da variabilidade seja realizado de acordo com os princípios da produção enxuta.

Existe uma diferença relativa entre a curva de decisão e a curva de contingência, que remete aos índices acumulados pelos dois algoritmos deste trabalho, unicamente pelo fato de estarem computando sobre espaços diferentes em margens de tolerância e parâmetros de regularização distintos. Como o índice da MVS é mais restritivo, optou-

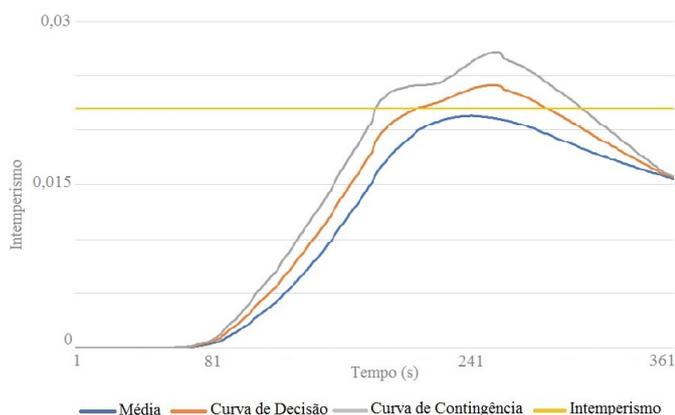


Figura 5. Curvas de Desvio Padrão com Alteração de Parâmetros da Produção

se por representar duas curvas que servem para aumentar a compreensão da tendência ao desenquadramento.

O algoritmo de máquina de vetor de suporte apresenta o melhor desempenho na simulação, porém a rede de Bayes é satisfatória para esta aplicação. Por fim, ao utilizar-se das ferramentas desenvolvidas a tomada de decisão torna-se fiável, e deste modo, a produção enxuta é obtida por meio da redução da variabilidade e monitoramento da tendência do processo.

REFERÊNCIAS

- Bahadori, A. (2014). *Natural gas processing: technology and engineering design*. Gulf Professional Publishing.
- Bakosova, M., Oravec, J., Vasickaninova, A., and Mészáros, A. (2017). Neural-network-based and robust model-based predictive control of a tubular heat exchanger. *Chemical Engineering Transactions*, 61, 301–306.
- de Almeida, J.d.S.C., Araújo, O.d.Q.F., and de Medeiros, J.L. (2016). Produção offshore de gás natural rico em CO_2 : Cenário dutos subsea com meg e processamento onshore.
- Diehl, F.C., Almeida, C.S., Anzai, T.K., Gerevini, G., Neto, S.S., Von Meien, O.F., Campos, M.C., Farenzena, M., and Trierweiler, J.O. (2018). Oil production increase in unstable gas lift systems through nonlinear model predictive control. *Journal of Process Control*, 69, 58–69.
- Faris, H., Aljarah, I., and Mirjalili, S. (2016). Training feedforward neural networks using multi-verse optimizer for binary classification problems. *Applied Intelligence*, 45(2), 322–332.
- Fatima, S.A., Zabiri, H., Taqvi, S.A.A., and Ramli, N. (2019). System identification of industrial debutanizer column. In *2019 9th IEEE International Conference on Control System, Computing and Engineering (IC-CSCE)*, 178–183. IEEE.
- Haykin, S. (2007). *Redes neurais: princípios e prática*. Bookman Editora.
- Huang, S., Cai, N., Pacheco, P.P., Narrandes, S., Wang, Y., and Xu, W. (2018). Applications of support vector machine (svm) learning in cancer genomics. *Cancer Genomics-Proteomics*, 15(1), 41–51.
- Jin, C. and Lim, Y. (2019). Optimization and economic evaluation of integrated natural gas liquids (ngl) and liquefied natural gas (lng) processing for lean feed gas. *Applied Thermal Engineering*, 149, 1265–1273.
- Kidnay, A.J., Parrish, W.R., and McCartney, D.G. (2019). *Fundamentals of natural gas processing*. CRC press.
- Loehlin, J.C. and Beaujean, A.A. (2016). *Latent variable models: An introduction to factor, path, and structural equation analysis*. Taylor & Francis.
- Marodin, G.A., Saurin, T.A., Tortorella, G.L., and Fettermann, D.d.C. (2018). Model of risk interactions hindering lean production implementation. *Gestao & Producao*, 25(4), 696–712.
- Martin, R., Mess, R., Walker, S.G., et al. (2017). Empirical bayes posterior concentration in sparse high-dimensional linear models. *Bernoulli*, 23(3), 1822–1847.
- Panapakidis, I.P. and Dagoumas, A.S. (2017). Day-ahead natural gas demand forecasting based on the combination of wavelet transform and anfis/genetic algorithm/neural network model. *Energy*, 118, 231–245.
- Sanders, A., Elangeswaran, C., and Wulfsberg, J.P. (2016). Industry 4.0 implies lean manufacturing: Research activities in industry 4.0 function as enablers for lean manufacturing. *Journal of Industrial Engineering and Management (JIEM)*, 9(3), 811–833.
- Saritas, M.M. and Yasar, A. (2019). Performance analysis of ann and naive bayes classification algorithm for data classification. *International Journal of Intelligent Systems and Applications in Engineering*, 7(2), 88–91.
- Sayed, A.E.R., Ashour, I., and Gadalla, M. (2017). Integrated process development for an optimum gas processing plant. *Chemical Engineering Research and Design*, 124, 114–123.
- Scholkopf, B. and Smola, A.J. (2018). *Learning with kernels: support vector machines, regularization, optimization, and beyond*. Adaptive Computation and Machine Learning series.
- Silva, R.D. et al. (2017). *Manual e check-list para acompanhamento de manutenções e prevenção de acidentes em instalações de gás LP*. Master's thesis, Instituto Federal de Educação, Ciência e Tecnologia do Piauí.
- Slack, N., Chambers, S., Johnston, R., and Betts, A. (2013). *Gerenciamento de Operações e de Processos: Princípios e práticas de impacto estratégico*. Bookman Editora.
- Tgarguifa, A., Abderafi, S., and Bounahmidi, T. (2017). Energetic optimization of moroccan distillery using simulation and response surface methodology. *Renewable and Sustainable Energy Reviews*, 75, 415–425.
- Thomas, J.E. et al. (2004). *Fundamentos de engenharia de petróleo*. 2ª edição. Editora Interciência.
- Tsangaratos, P. and Iliá, I. (2016). Comparison of a logistic regression and naïve bayes classifier in landslide susceptibility assessments: The influence of models complexity and training dataset size. *Catena*, 145, 164–179.
- Witten, I., Frank, E., Hall, M., and Pal, C. (2017). *Data mining: practical machine learning tools and techniques*. Elsevier.
- Womack, J.P. and Jones, D.T. (2017). *Lean thinking. Come creare valore e bandire gli sprechi*. goWare & Guerini Next.
- Zhou, J., Kooijman, H., and Taylor, R. (2019). Parallel column model for dividing wall column simulations. *Computers & Chemical Engineering*, 125, 114–133.