

AUMENTO DA EFICIÊNCIA ENERGÉTICA DOS FORNOS DE PIRÓLISE DE NAFTA UTILIZANDO SOFTWARE ESTATÍSTICO

Luane Cristiane Angeli – Aluna do Curso de Engenharia Química
Escola Politécnica – PUCRS

Resumo

A eficiência energética é um tema de crescente relevância na indústria petroquímica, dado o impacto econômico e ambiental associado ao alto consumo de energia em processos industriais. O forno de pirólise, utilizado no craqueamento de nafta para a produção de olefinas como eteno e propeno, é um dos responsáveis por essa demanda. Este estudo analisou e identificou as variáveis que influenciam o desempenho energético desse equipamento, desenvolvendo um modelo empírico no software *Aspen ProMV* baseado na Análise de Componentes Principais (PCA). A metodologia permitiu identificar variáveis operacionais críticas, como a abertura da válvula (*Damper*) na sucção, além de problemas como o acúmulo de resíduos nas bancadas de convecção, que prejudicam a troca térmica e elevam o consumo de energia. O modelo offline representou bem o comportamento do forno, demonstrando eficiência tanto no ajuste dos dados quanto na previsão de comportamentos futuros. Essas informações oferecem uma base sólida para otimizar a operação do forno, reduzindo o consumo de energia e promovendo práticas mais sustentáveis no setor petroquímico, alinhando eficiência operacional e sustentabilidade como resultados chave.

Palavras-chave: Eficiência energética. Fornos de pirólise. Análise de Componentes Principais.

Abstract

Energy efficiency is a topic of increasing relevance in the petrochemical industry, given the economic and environmental impact associated with high energy consumption in industrial processes. The pyrolysis furnace, used in naphtha cracking for the production of olefins such as ethylene and propylene, is a significant contributor to this demand. This study analyzed and identified the variables influencing the energy performance of this equipment by developing an empirical model in Aspen ProMV software, based on Principal Component Analysis (PCA). The methodology identified critical operational variables, such as the Damper valve opening in the suction system, as well as issues like residue buildup on convection banks, which impair heat exchange and increase energy consumption. The offline model accurately represented the furnace's behavior, demonstrating efficiency in both data fitting and the prediction of future behaviors. This information provides a solid foundation for optimizing furnace operation, reducing energy consumption, and promoting more sustainable practices in the petrochemical sector, aligning operational efficiency and sustainability as key outcomes.

Keywords: Energy efficiency. Pyrolysis furnaces. Principal Component Analysis.

Lista de Abreviações

CIT - Temperatura na entrada da zona de radiação, do inglês *coil inlet temperature*;

COT - Temperatura de operação na zona de radiação, do inglês *coil outlet temperature*;

DSH - Aquecimento de vapor de diluição, do inglês *Dilution Steam Heater* aquecedor;

ECO - Pré-aquecedor, do inglês *Economizer*;

HC – Hidrocarboneto;

HPSS - Superaquecimento de vapor de super alta pressão, do inglês *High Pressure Steam Superheater*;

HTC - Superaquecimento nos tubos, do inglês *High Temperature Coil*;

HVC - Qualidade da carga, do inglês, *High Value Chemicals*;

KPI - indicador-chave de desempenho, do inglês *Key Performance Indicator*;

NPH - Pré-aquecedor de hidrocarbonetos, do inglês *Naphtha Preheater*;

TLX's ou *TLE's* - Linha de transferência, do inglês *Transfer Line Exchange*;

VD – Vapor de diluição;

VTI - Ventilador de tiragem induzida.

1 Introdução

Na indústria química, a conservação de energia tornou-se uma preocupação crescente. O aumento contínuo dos custos dos insumos energéticos, a redução da disponibilidade de combustíveis e as crescentes restrições ambientais às emissões de poluentes justificam o investimento em projetos industriais que visam minimizar o consumo energético. Em décadas passadas, as preocupações com o consumo energético eram menores e as ferramentas para avaliar e projetar plantas eram limitadas, o que cria oportunidades para a otimização energética das plantas industriais existentes (Nóbrega., 2018).

De forma simplificada, a busca pela otimização energética de um processo industrial pode ser dividida em duas abordagens: (i) a modificação do fluxo do processo, ou seja, a reordenação das operações unitárias e o redirecionamento das correntes de processo; (ii) a atuação direta no equipamento, ou seja, como a modificação do mesmo, a otimização dos ciclos de operação/manutenção e o ajuste dos parâmetros operacionais, visando minimizar o consumo energético do equipamento de forma pontual e direta. A primeira abordagem, é denominada como integração energética, onde o objetivo é melhorar o desempenho do processo como um todo; na segunda, o foco é o desempenho individual do equipamento. Ambas contribuem para a redução do consumo de energia, mas com abordagens, metodologias e custos de investimento diferentes (Beninca., 2008).

A integração energética é a área de estudo da engenharia voltada para a otimização energética de processos produtivos, e é definida como métodos gerais e sistemáticos para o projeto de sistemas de produção integrados, que vão desde processos individuais até processos industriais complexos (Hugenthobler, 2020). Essa abordagem, visualiza o processo constituído de três partes básicas: um conjunto de operações unitárias, representadas por equipamentos de processo (reatores, torres, vasos, etc.); um conjunto de correntes de processo que interligam as operações unitárias mencionadas, e que possuem parâmetros fixos – temperaturas de entrada e saída, composição e capacidade térmica – que por sua vez podem ser subdivididas em correntes de processo quentes e frias, e correntes de utilidades quentes e frias; e uma rede de permutadores de calor responsável pela troca de energia entre as correntes quentes e frias (Beninca, 2008).

Mais especificamente, quando se aplica a segunda abordagem, é possível concentrar o estudo de otimização e os investimentos no processo onde a demanda por

energia é maior, para permitir uma alocação mais eficiente dos recursos e maximizar os benefícios da otimização energética (Beninca., 2008).

Na indústria petroquímica o craqueamento térmico de hidrocarbonetos para a produção de olefinas leves, como eteno e propeno, é uma operação primária para determinação do ciclo produtivo. Eles são a fonte primária de produção de uma grande variedade de polímeros e fibras sintéticas. O processo, conduzido em um forno de pirólise demanda um alto valor de energia, para realizar uma sequência de reações endotérmicas que ocorrem quando a matéria-prima, seja ela líquida (nafta, gás óleo) ou gasosa (etano, propano), é alimentada em um reator tubular (serpentina) e submetida a altas temperaturas na presença de vapor de água (Soledar, 2015).

O rendimento e o consumo de energia em fornos de craqueamento de nafta são impactados por um conjunto complexo de variáveis. Para analisar a correlação entre estas variáveis, podem ser utilizadas ferramentas de matemática estatística, tornando possível realizar ajustes nos parâmetros operacionais, a fim de minimizar o consumo energético. Este trabalho mostra como uma dessas ferramentas pode ser utilizada para aumentar a eficiência energética em fornos de pirólise.

2 Fundamentação Teórica

2.1 Breve Descrição da Cadeia Petroquímica

A indústria petroquímica é responsável pela transformação de matérias-primas como etano, propano, nafta, gás natural em produtos de alto valor agregado e que são utilizados no dia a dia da sociedade moderna. A cadeia petroquímica é caracterizada pelos produtos de 1ª geração, que são os petroquímicos básicos, os de 2ª geração, que são as resinas e os intermediários, e os de 3ª geração, que são os produtos de transformação como embalagens para o setor alimentício, automotivo, eletrônicos entre outros (GOMES et al, 2005). Na figura 1 temos a cadeia petroquímica exemplificada.




Figura 1: Cadeia petroquímica. (Fonte: Abiplast, 2012)

Como podemos observar na Figura 1, a cadeia petroquímica começa pelo refino do petróleo no qual é obtida a nafta, principal matéria prima para a cadeia. Após o refino, a nafta passa pelo processo de craqueamento e são geradas as olefinas e os petroquímicos básicos (1ª geração). Por processos de polimerização são obtidas as resinas termoplásticas (2ª geração). Finalmente, a 2ª geração sofre processos de transformação e são fabricados produtos com diversas aplicações a diferentes segmentos do mercado (3ª geração).

2.2 Descrição de uma Planta de Olefinas

O eteno e o propeno, produtos principais da indústria petroquímica, são geralmente obtidos através da reação de pirólise (craqueamento) de matérias-primas como hidrocarbonetos leves (etano e propano), nafta ou gás óleo. Após o craqueamento, os gases são direcionados para a seção de fracionamento primário, que tem como objetivo condensar o óleo pesado e a gasolina pesada, além de recuperar o vapor injetado nos fornos. Esta seção é fundamental para a recuperação energética da planta, utilizando o calor das correntes de óleo, gasolina e água para aquecer diversas correntes na área de compressão e separação criogênica. A corrente gasosa que não foi condensada no fracionamento primário, segue para ser comprimida a fim de vencer a perda de carga

imposta pelas colunas de destilação da área de fracionamento (purificação). Esta área também é responsável por condensar hidrocarbonetos líquidos leves e remover gases ácidos através de um tratamento químico com soda, além de promover a completa secagem da corrente. A corrente gasosa, agora chamada de gás seco, segue para a separação criogênica e purificação dos principais produtos da planta (eteno e propeno), até atingir a especificação desejada pelo cliente (Soledar, 2015). A Figura 1 mostra o processo simplificado de uma planta petroquímica de olefinas.




Figura 2: Fluxograma simplificado de uma planta de olefinas. (Fonte: www.gasandoil.com)

2.3 Funcionamento de um Forno de Pirólise

Em uma unidade de insumos básicos, a nafta é craqueada nos chamados fornos de pirólise, fonte dos principais produtos da indústria petroquímica de 1ª geração, como o eteno e propeno. A carga passa por um pré-aquecedor de hidrocarbonetos (NPH, do inglês *Naphtha Preheater*), que é a primeira seção de topo da zona de radiação do forno, etapa responsável pelo aquecimento e evaporação parcial da nafta. Vapor é superaquecido na bancada de aquecimento de vapor de diluição (DSH, do inglês *Dilution Steam*

Heateraquecedor) e adicionado à matéria-prima a fim de reduzir a pressão parcial das moléculas aromáticas de alta massa molecular, reduzindo assim a influência das reações de condensação e colaborando para minimizar a formação de coque. Posteriormente, a corrente segue para o último superaquecimento nos tubos (HTC, do inglês *High Temperature Coil*). Em seguida a mistura entra nas serpentinas, ou seja, em reatores tubulares longos e dispostos verticalmente em uma câmara de combustão (zona de radiação) ampla e retangular onde ocorre a reação a temperaturas que variam de 800 – 1000°C (Soledar, 2015).

O gás craqueado passa pelos trocadores de calor da linha de transferência (TLX's ou TLE's, do inglês *Transfer Line Exchange*) localizados na saída da zona de radiação, que tem como principal objetivo interromper as reações secundárias de craqueamento e limitar a formação de coque. Além disso, os TLX's aproveitam o calor da corrente efluente, gerando vapor de alta pressão. Isso é feito utilizando água desmineralizada, que passa pelo pré-aquecedor (ECO, do inglês *Economizer*) da convecção, sendo enviado para um vaso no topo do forno. Esse vaso mantém um equilíbrio bifásico: a fase líquida a alta temperatura e pressão, faz a troca térmica nos TLX's, onde é parcialmente vaporizada e retorna ao vaso, a fase vapor, cujo excesso sai do topo do vaso, passa pela seção onde ocorre o superaquecimento de vapor de super alta pressão (HPSS, do inglês *High Pressure Steam Superheater*), sendo este vapor enviado para consumo interno nas turbinas de grandes compressores do cracker. Figura 3 apresenta o diagrama simplificado de um forno de pirólise (Soledar, 2015).

Os fornos de pirólise operam em um período que podem variar de 10 a 90 dias, dependendo da matéria-prima e condições operacionais, as quais podem gerar quantidades variadas de coque junto à parede da serpentina (Soledar, 2015).




Figura 3: Diagrama simplificado de um forno de pirólise genérico. (Fonte: Soledar L., 2015)

2.4 Eficiência energética

A eficiência energética consiste em obter o melhor desempenho na produção de um composto com o menor gasto de energia. No caso em uma planta de olefinas, equivale a ter o melhor desempenho na produção de eteno e propeno com o menor consumo de gás combustível nos fornos de pirólise, já que na matriz energética os fornos têm a participação de 75% sobre o custo total de operação. A eficiência térmica dos fornos é afetada pelo consumo de combustível, onde essa eficiência pode ser maximizada com o ajuste das variáveis de operação (Rebordinos, 2019).

2.5 Variáveis de operação

A eficiência dos fornos de pirólise de nafta é dependente das condições operacionais (Barazandeh, 2015). No forno, há uma grande quantidade de variáveis operacionais, e cada componente interfere na performance do craqueamento. Esses componentes, quando não estão devidamente ajustados, podem comprometer fortemente

a eficiência dos fornos de pirólise (Costa, 2019). São eles:

- Câmara de convecção;
- Secção de radiação: serpentina e queimadores;
- Ventilador de tiragem induzida.

Para compreender melhor a influência de cada uma dessas variáveis na eficiência dos fornos de pirólise, é necessário analisar individualmente os principais componentes mencionados. A seguir, estas variáveis serão detalhadas com suas funções e impactos operacionais, destacando a importância de seus ajustes adequados no desempenho do processo de craqueamento.

2.5.1 Câmara de convecção

A seção de convecção de cada forno de pirólise, conforme já mencionado, pode ser composta por quatro ou mais bancos de tubos a depender do projeto, em que cada um deles possui uma finalidade diferente de acordo com suas posições. A convecção de quatro bancos normalmente possui a seguinte configuração e finalidade:

- Seção de aquecimento e vaporização de carga de hidrocarbonetos;
- Seção de pré-aquecimento de água desmineralizada (AD);
- Seção de superaquecimento de vapor de diluição (VD); e
- Seção de aquecimento da mistura (HTC), onde a mistura é composta pela carga de hidrocarboneto (HC) com o vapor de diluição (VD).

O projeto e o controle das variáveis de processo preveem que a carga seja vaporizada na seção de convecção de modo a não formar coque no interior dos tubos da serpentina, principalmente aqueles situados na entrada da seção de radiação. Logo, o controle da pressão e da temperatura de entrada do HC é necessário para garantir que a energia trocada pelos gases de combustão proveniente da radiação seja suficiente para ocorrer a vaporização do HC (Costa, 2019).

2.5.2 Seção de Radiação

Na entrada da zona de radiação (início da serpentina), tem-se a continuidade do aquecimento da carga de hidrocarbonetos misturada com o vapor de diluição, que foi

iniciado na convecção. À medida que as temperaturas vão se elevando, as reações de craqueamento vão ocorrendo, onde as cadeias maiores são divididas em cadeias menores, formando produtos e radicais livres que continuam reagindo ao longo da serpentina.

A serpentina do forno de pirólise na zona de convecção é formada por passes de carga de hidrocarboneto e vapor de diluição. Cada passe, ao atingir a zona de radiação, se divide em novos passes de menor diâmetro que o original. Os passes se dividem dois a dois através de arranjos tipo "Y" e enviam a carga de HC e o vapor d'água, mistura efluente do forno, para um trocador da linha de transferência (TLX) (Costa, 2019).

Já os queimadores presentes na radiação, são responsáveis pela maior parte da energia cedida para os fornos de pirólise, pois a entrada de gás combustível utilizado para ocorrer combustão se dá neles (Bueno, 2016).

2.5.3 Ventilador de tiragem induzida

O ventilador de tiragem induzida (VTI) é responsável pela tiragem do forno. Devido a diferença de densidade entre os gases de combustão no interior do forno e o ar atmosférico, ocorre um diferencial de pressão entre a câmara de combustão e o meio externo, sendo que este diferencial diminui em função da altura. Para vencer a perda de carga na seção de convecção, a válvula (*Damper*) na sucção do VTI deve ser ajustado de modo que a pressão no topo da radiação seja inferior do que a pressão na base da radiação (Costa, 2019). Como mostrdo nas Figuras 4 e 5, há diferentes ajustes para o *Damper*, fechado e aberto.




Figura 4: *Damper* fechado (Fonte: <https://grabcad.com/tutorials/vortex-damper-mechanism-in-solidworks>, acessado setembro/2024).




Figura 5: *Damper* aberto (Fonte: <https://grabcad.com/tutorials/vortex-damper-mechanism-in-solidworks>, acessado setembro/2024).

Alguns fatores podem sobrecarregar o VTI, causando limitação na sua capacidade de exaustão dos gases de combustão e provocando redução na carga do forno. Dentre estes fatores, um dos principais é aumento do excesso de ar (medido pela %O₂) (Costa, 2019).

2.5.4 Parâmetros de Operação

As reações que maximizam a produção de eteno ocorrem em condições extremas na secção de radiação em altas temperaturas, tempos de residência, com uma especificação para a matéria-prima processada, pressões baixas e utilizando vapor de diluição para reduzir a pressão parcial dos hidrocarbonetos e a formação de coque (Bueno, 2016).

Considerando que a geometria e a configuração do forno já estão definidas, a eficiência do craqueamento para a produção de eteno fica em função do tempo de residência, da temperatura de operação na zona de radiação (COT, do inglês *coil outlet temperature*) e da pressão de entrada da serpentina (Costa, 2019).

Além da COT, também é importante acompanhar a temperatura na entrada da zona de radiação (CIT, do inglês *coil inlet temperature*), pois valores acima do especificado no projeto indicam que a reação de pirólise será iniciada na zona da convecção, reduzindo o tempo de campanha do forno devido a formação de depósitos nesta secção. O controle da CIT depende dos sistemas de pré-aquecimento de carga e dos parâmetros de operação do forno. Não existem controles associados à CIT. A temperatura controlada no forno de pirólise é a COT, pois, a depender da temperatura de operação, pode haver favorecimento da produção de eteno e/ou propeno, como mostra a Quadro 1.

Rendimento dos Produtos (%peso)	Temperatura (°C)		
	815	835	855
Hidrogênio	0,66	0,74	0,81
Metano	13,82	15,65	17,40
Eteno	24,71	27,06	29,17
Propeno	17,34	16,28	14,44
Butadieno	4,18	9,17	3,99
Benzeno	4,89	5,90	7,08
Gasolina	22,64	20,89	20,01

Quadro 1: Efeito da Temperatura nos rendimentos dos produtos. (Adaptado Leite, 2013)

Já o tempo de residência pode ser definido de forma simplificada como o tempo gasto por uma unidade de carga para atravessar toda a serpentina da radiação onde ocorrem as reações de pirólise. O efeito do tempo de residência sobre a seletividade se deve ao fato das olefinas serem produzidas por reações primárias e por isto requerem um tempo de residência muito baixo. O aumento do tempo de residência, por sua vez, favorece as reações secundárias, isto é, a produção de compostos aromáticos e coque, às expensas de olefinas formadas por reações primárias (Costa, 2019).

O tempo de residência depende dos seguintes parâmetros:

- Geometria da serpentina: quanto maior for o comprimento da serpentina e maior for o seu diâmetro, maior será o tempo de residência (Costa, 2019);

- COT: é uma variável chave neste processo, pois determina a cinética das reações, além de ter forte influência no tempo de campanha das serpentinas. Quanto maior a temperatura, maior será o volume específico dos gases, aumentando a velocidade e diminuindo o tempo de residência. Por outro lado, quanto maior for o COT maior será a vazão de gás combustível do forno, logo maior temperatura na superfície da serpentina (Costa, 2019);

- Razão VD/HC: elevar a razão VD/HC aumenta a velocidade e, consequentemente, diminui o tempo de residência. No entanto, aumentando muito a carga e/ou vapor de diluição aumentará também a perda de carga na serpentina, elevando consequentemente a pressão da carga (Costa, 2019).

O vapor de diluição é injetado com a carga do forno para controlar a pressão parcial dos hidrocarbonetos, visando aumentar a produção de olefinas e diminuir a produção de coque nas serpentinas e TLX's. A razão ótima VD/HC depende das propriedades da carga e de fatores econômicos determinados pelo consumo de energia e

pela seletividade dos produtos da pirólise (Costa, 2019).

Maiores relações VD/HC favorecem a uma maior produção de olefinas e minimizam a deposição de hidrocarboneto (coque) na serpentina dos fornos, devido à redução da pressão parcial dos hidrocarbonetos. Porém, a operação com razões VD/HC maiores que a de projeto deve ser feita com muito cuidado, porque o aumento excessivo da velocidade pode causar erosão em curvas das serpentinas. Isto depende do projeto do forno e do tipo de carga (Costa, 2019).

- Pressão de operação: o efeito da pressão de operação será contrário ao da temperatura. Quanto menor é a pressão, maior será o volume e consequentemente menor o tempo da residência. A pressão de operação será influenciada pelos aspectos geométricos das serpentinas, pela razão VD/HC, e pela diferença de pressão da entrada e saída existente no sistema. Portanto, procura-se operar os fornos de pirólise com a menor pressão possível (Costa, 2019).

O perfil da pressão parcial dos hidrocarbonetos ao longo da serpentina do forno é fator importante para definir o rendimento da pirólise. As pressões parciais de hidrocarbonetos e vapor se somam para compor a pressão total, como mostra a equação 1. A pressão total decresce ao longo da serpentina devido à perda de carga. Altas pressões parciais de hidrocarbonetos conduzem as reações secundárias indesejadas. Baixas pressões parciais melhoram o rendimento de etileno (Costa, 2019).

$$P_{total} = P_{hidrocarboneto} + P_{vapor\ de\ diluição} \quad (1)$$

Os rendimentos dependem da matéria-prima processada e da estrutura da cadeia hidrocarbônica. A qualidade da carga identifica o potencial em gerar produtos de alto valor agregado também conhecidos pela sigla em inglês HVC (do inglês, *High Value Chemicals*). Geralmente são considerados HVC: Eteno, propeno, hidrogênio, 1,3 butadieno e o benzeno contido na gasolina de pirólise. Foi desenvolvido, então, um fator de qualidade para as naftas, a razão entre o percentual de iso-parafinas e n-parafinas (I/P). Quanto menor esta razão, a nafta tenderá a produzir mais eteno e hidrogênio. Quanto maior a razão de I/P a nafta terá um maior potencial para gerar propeno e metano (LUMMUS, 2010).

2.6 Tipos de Modelos

A técnica de modelagem matemática para representação de processos industriais é

muito utilizada dentro da engenharia química. Com avanços nas ferramentas computacionais e na capacidade de processamento, cada vez mais tem-se desenvolvido pesquisas nas áreas de modelagem e simulação (Silva, 2012).

Além de serem utilizados na simulação dos processos, os modelos também podem ser empregados na otimização. A otimização tem o intuito de encontrar um ponto ótimo de operação em função de um conjunto de variáveis alimentadas. Assim, é importante avaliar qual o melhor modelo a ser utilizado para representar o problema que está sendo avaliado (Burden, 2010).

Existem várias possibilidades de aplicações de diferentes modelos. As técnicas podem se empíricas ou fenomenológicas. As categorias de modelagem podem ser divididas em três grupos:

Modelos fenomenológicos: relacionam as variáveis secundárias e as primárias através de equações que descrevem o comportamento termodinâmico do sistema, balanço de massa e energia, equações constitutivas, cinéticas de reação etc., ou seja, possuem um foco voltado ao fenômeno e usa leis e modelos teóricos para descrevê-lo (Conz., 2005).

Modelos empíricos: são modelos sem qualquer base fenomenológica utilizando tipicamente técnicas de análise estatísticas mono ou multi-variáveis e modelos de regressão para estabelecer uma relação entre dados de entrada e saída (Conz., 2005).

Modelos semi-empíricos: são modelos baseados normalmente em simplificações de modelos fenomenológicos, os quais durante o processo de simplificação, acabam gerando parâmetros que precisam ser ajustados através de métodos estatísticos para estimação de parâmetros (Conz., 2005).

Os modelos fenomenológicos são os modelos com maior capacidade extrapolativa, sua obtenção, no entanto, geralmente demanda um elevado esforço, e consequentemente muito tempo para o seu desenvolvimento, especialmente em sistemas complexos (Conz., 2005).

Modelos empíricos, por sua vez, são caracterizados por não possuírem nenhuma base fenomenológica do sistema a ser modelado. Eles são a aplicação de métodos matemáticos, capazes de representar a relação entre as variáveis de entrada e saída de um processo. Sua capacidade extrapolativa é reduzida quando comparada a dos modelos

fenomenológicos. Outro fator que deve ser levado em conta, quando se utiliza um modelo empírico, é que eles são capazes somente de modelar os dados e não modelar o processo como um todo (Conz., 2005).

2.7 Técnicas de Obtenção de Modelos Empíricos

Em geral, métodos empíricos multivariáveis são usados na construção de modelos, tanto pela sua praticidade quanto pelos bons resultados. Os modelos empíricos se diferem dos fenomenológicos e semi-empíricos pelo fato de que não utilizam relações físico-químicas entre as variáveis de entrada e saída, e sim tratamentos estatísticos que as relacionem (Conz., 2005).

A maioria das medições de processo adquiridas de sistemas de controle em indústrias são de alta dimensionalidade, têm baixas relações e dados ausentes. O monitoramento estatístico multivariado usando técnicas de visualização e projeção do conjunto de dados brutos em um plano transformado ajuda a interpretar o conjunto de dados (Agarwal, 2022). Em sistemas complexos, que envolvem elevado número de variáveis, devem ser empregadas técnicas multivariáveis, nas quais são considerados não apenas os valores individuais das variáveis, mas também a correlação entre elas (correlação espacial). Dentre estas, uma das principais técnicas empregada é a Análise de Componentes Principais (PCA, do inglês *Principal Component Analysys*) (Brito, 2014).

2.7.1 Análise de Componentes Principais (PCA)

A Análise de Componentes Principais foi inventada por Karl Pearson, em 1901. É utilizada principalmente como um instrumento de análise exploratório de dados e para construir modelos preditivos (Loesch., 2017).

A PCA é uma técnica estatística amplamente utilizada para redução de dimensionalidade, transformando um conjunto de variáveis correlacionadas em um novo conjunto de variáveis, chamadas componentes principais. Essas componentes são ordenadas de forma que a primeira componente captura a maior variação dos dados, a segunda captura a maior variação possível na direção ortogonal à primeira, e assim por diante. A Análise de Componentes Principais é um método eficaz para simplificar a análise de dados complexos, preservando as principais informações do sistema (Hotelling, 1933). A técnica é frequentemente combinada com métricas como a estatística T^2 de Hotelling e o erro quadrático de reconstrução (SPE, Squared Prediction Error) para

monitoramento de processos e diagnóstico de anomalias (Britto, 2014).

A PCA pode ser reduzida ao problema de encontrar os autovalores e autovetores da matriz de covariância (ou correlação) do conjunto de dados. Dada uma matriz de dados X , que contém as observações de um sistema. Cada linha da matriz representa uma observação, e cada coluna representa uma variável do sistema. Se tivermos n observações e p variáveis, a matriz X terá dimensões $n \times p$ (Britto, 2014).

$$X = \begin{bmatrix} X_{11} & \cdots & X_{p1} \\ \vdots & \ddots & \vdots \\ X_{n1} & \cdots & X_{np} \end{bmatrix} \quad (2)$$

2.7.1.1 Centragem dos dados

O primeiro passo na aplicação do PCA é a centragem dos dados. A centragem consiste em subtrair a média de cada variável (coluna) para que todas as variáveis possuam média zero (Jolliffe, 2002). Se X é a matriz de dados original, de dimensão $n \times p$, em que cada linha i representa uma observação e cada coluna j uma variável, a matriz centrada $X_{centrado}$ é dada por:

$$X_{centrado} = X - \mu \quad (3)$$

onde μ é um vetor de médias de dimensão $1 \times p$, dado por:

$$\mu = \frac{1}{n} \sum_{i=1}^n X_i \quad (4)$$

Subtrair a média de cada variável garante que o PCA se concentre nas variações relativas entre as variáveis e não nas suas magnitudes absolutas (Shlens, 2014).

2.7.1.2 Cálculo da Matriz de Covariância

Após a centragem, o próximo passo é calcular a matriz de covariância dos dados centrados. A covariância mede a relação linear entre duas variáveis, indicando como as variáveis se movem juntas (Jolliffe, 2002). A matriz de covariância C para os dados $X_{centrado}$ é dada por:

$$C = \frac{1}{n-1} X_{centrado}^T X_{centrado} \quad (5)$$

onde C é uma matriz $p \times p$, em que cada elemento C_{ij} representa a covariância entre as variáveis i e j . A matriz de covariância é simétrica e fornece informações sobre

como as variáveis estão correlacionadas entre si. Se as variáveis forem altamente correlacionadas, os elementos fora da diagonal de C terão valores elevados (Jolliffe, 2002).

2.7.1.3 Cálculo de Autovetores e Autovalores

A partir da matriz de covariância, o próximo passo no PCA é calcular os autovetores e autovalores de C . Os autovetores são as direções principais (ou componentes principais) nos dados, enquanto os autovalores indicam a quantidade de variação explicada por cada autovetor (Hotelling, 1933). Matematicamente, a equação para calcular os autovetores e autovalores é dada por:

$$Cv = \lambda v \quad (6)$$

Onde v é o autovetor (direção principal) e λ é o autovalor (a quantidade de variabilidade explicada ao longo de v). Os autovetores v são normalizados, ou seja, possuem comprimento unitário, e os autovalores λ são positivos. O autovetor correspondente ao maior autovalor é a direção de maior variação nos dados, e os autovetores subsequentes, correspondentes aos próximos autovalores, indicam as direções de menor variação, sendo todos ortogonais entre si (Jolliffe, 2002).

Os autovetores são ordenados de acordo com os autovalores, em ordem decrescente. O autovetor com o maior autovalor representa o primeiro componente principal, que é a direção de maior dispersão dos dados. O segundo autovetor, associado ao segundo maior autovalor, representa o segundo componente principal, e assim por diante (Jolliffe, 2002).

2.7.1.4 Escolha do Número de Componentes principais

O número de componentes principais a ser mantido depende da variância explicada e dos objetivos da análise (Jolliffe, 2002). A variância explicada por cada componente principal k é dada pela razão entre o autovalor λ_k do componente k e a soma de todos os autovalores:

$$k = \frac{\lambda_k}{\sum_{k=1}^p \lambda_k} \quad (7)$$

Essa razão indica quanto da variabilidade total dos dados é capturada pelo

componente principal k . Componentes com maiores autovalores são mais importantes, pois explicam uma maior parte da variância (Jolliffe, 2002).

Em muitas situações, é desejável reduzir a dimensionalidade do conjunto de dados. Para isso, escolhemos os primeiros k componentes principais, onde k é menor que p . A escolha de k depende da soma acumulada da variância explicada. Por exemplo, pode-se escolher k de modo que os primeiros componentes expliquem, por exemplo, 90% ou 95% da variabilidade total dos dados (Jolliffe, 2002).

A soma acumulada da variância explicada pelos k primeiros componentes é dada por:

$$\text{Variância acumulada} = \sum_{k=1}^k \frac{\lambda_k}{\sum_{k=1}^p \lambda_k} \quad (8)$$

Este valor ajuda a decidir o número de componentes a ser mantido, garantindo que a maior parte da informação dos dados originais seja preservada (Jolliffe, 2002).

2.7.1.5 Projeção dos Dados nos Componentes Principais

Após selecionar os k componentes principais, projetamos os dados originais X_{centrado} nos autovetores correspondentes aos k primeiros componentes principais (Shlens, 2014). A matriz V_k é uma matriz $p \times k$ que contém os k primeiros autovetores, e a projeção dos dados nos componentes principais é dada por:

$$Z = X_{\text{centrado}} V_k \quad (9)$$

Aqui, Z é a matriz $n \times k$ dos dados projetados, onde cada linha representa uma observação e cada coluna um componente principal. A matriz Z é a versão reduzida do conjunto de dados, com k variáveis em vez de p . Os dados projetados em Z podem ser analisados para descobrir padrões, agrupar observações ou identificar outliers. Cada componente principal é uma combinação linear das variáveis originais, e a interpretação de cada componente depende dos coeficientes dos autovetores. A contribuição de cada variável original para um componente pode ser verificada examinando os elementos do autovetor correspondente. Componentes com coeficientes altos em determinadas variáveis indicam que essas variáveis são influentes para o componente principal (Shlens, 2014).

2.7.2 Teste de Hotelling T^2

O Teste de Hotelling T^2 é uma extensão multivariada do teste t de Student, e é frequentemente utilizado para identificar outliers ou anomalias nos dados (Hotelling, 1933). Após aplicar o PCA e reduzir a dimensionalidade, o Teste de Hotelling T^2 pode ser usado para calcular a distância de uma observação em relação à média do conjunto de dados projetado. A fórmula do T^2 é dada por:

$$T^2 = Z^T \hat{\Sigma}^{-1} Z \quad (10)$$

Onde Z é o vetor de observações projetadas nos componentes principais e $\hat{\Sigma}$ é a matriz de covariância dos componentes principais (Johnson & Wichern, 2007). Observações com um valor de T^2 muito alto são consideradas anômalas, pois estão distantes da "região de normalidade" definida pelos dados.

2.7.3 Erro de Previsão Squared (SPE)

O Erro de Previsão Squared (SPE), também conhecido como resíduo quadrado ou SPE score, mede a diferença entre a projeção dos dados no espaço dos componentes principais e a reconstrução dos dados. Esse erro ajuda a identificar pontos que não se ajustam bem ao modelo de PCA, ou seja, que não podem ser representados de maneira eficiente pelas primeiras componentes principais (Shlens, 2014). O cálculo do SPE é dado por:

$$SPE = \| X - ZV_k^T \|^2 \quad (11)$$

Onde Z são os dados projetados e V_k é a matriz de autovetores correspondentes aos componentes principais selecionados. Valores de SPE elevados indicam que a observação não é bem representada pelos componentes principais, sugerindo que pode ser um ponto atípico ou uma anomalia (Shlens, 2014).

O PCA é uma técnica poderosa para redução de dimensionalidade, facilitando a análise e a visualização de grandes conjuntos de dados. Além de melhorar a interpretação dos dados, o PCA pode ser combinado com o Teste de Hotelling T^2 e o Erro de Previsão Squared (SPE) para monitorar a qualidade dos dados, detectar anomalias e identificar padrões incomuns. Esses testes são úteis em aplicações como monitoramento de processos industriais, detecção de falhas em sistemas e análise de outliers, tornando o PCA uma ferramenta versátil tanto para análise exploratória quanto para diagnóstico de

problemas em dados multivariados (Shlens, 2014).

3 Materiais e Métodos

O primeiro passo na modelagem consiste na seleção das variáveis que serão utilizadas para representar o forno de pirólise. Como discutido na seção 2.5, existem diversas variáveis controladas para o funcionamento do forno. Embora o software utilizado, *Aspen ProMV* — uma ferramenta estatística para a construção de modelos de Análise de Componentes Principais (PCA) e para gerar visualizações que auxiliam na detecção de anomalias, redução de dimensionalidade e exploração das relações entre as variáveis (Agarwal, 2022) — permita o uso de todas as variáveis disponíveis, neste estudo foi realizada uma pré-seleção com base na fundamentação teórica apresentada anteriormente.

Além dos dias de campanha do forno e da variável utilizada para mostrar a eficiência do forno, pode-se dividir a seleção das demais variáveis que são medidas por instrumentos em duas seções:

Secção de convecção:

- ✓ Vazão de HC [t/h];
- ✓ Temperatura de Entrada de HC [°C];
- ✓ Pressão de entrada do HC na zona de convecção [kgf/cm²];
- ✓ Temperatura do VD [°C];
- ✓ Vazão de VD [t/h];
- ✓ Pressão de entrada do VD na zona de convecção [kgf/cm²];
- ✓ Razão de VD/HC;
- ✓ Pressão de entrada da mistura (VD+HC) na zona de radiação [kgf/cm²];
- ✓ Parafinicidade (n-P+i-P) [%massa];
- ✓ Abertura do Damper [%];
- ✓ O₂ [%]

- ✓ Tiragem do Forno [mmH₂O];
- ✓ Temperatura de Chaminé [°C];

Secção de radiação:

- ✓ COT [°C];
- ✓ CIT [°C];
- ✓ Vazão de GC [t/h];
- ✓ Poder Calorífico Interno (PCI) do Gás Combustível [kcal/kg];
- ✓ Densidade do Gás Combustível [kg/m³];

Os dados utilizados foram coletados de um processo industrial. Para preservar os dados reais da empresa, foi utilizado um coeficiente onde foi possível mudar os valores e manter a variabilidade entre os dados. Os dados foram coletados com frequência horária, em um período de um ano e meio, pois como houve a diminuição das variáveis, um número elevado de amostras, permite uma maior assertividade no modelo.

A variável escolhida como objetivo a ser minimizado, ou seja, o indicador-chave de desempenho (KPI, do inglês *Key Performance Indicator*), foi calculada com base nos valores utilizados neste estudo. Para determinar os valores do KPI, inicialmente foi calculada a energia consumida pelo forno:

$$CTerm = \frac{PCI_{GC} * V_{GC}}{1000} \quad (11)$$

Onde CTerm indica a energia consumida no forno [Gcal/h], o PCI GC é o poder calorífico inferior do gás combustível [kcal/kg] e o V GC é a vazão que entra de gás combustível [t/h], o número “1000” foi utilizado para a análise dimensional, pois os parâmetros utilizados no cálculo são obtidos em unidades fixas e para obter uma melhor visualização dos dados, é interessante a mudança da unidade. De posse do CTerm, é possível calcular o KPI:

$$KPI = \frac{CTerm}{V_{HC}} \quad (12)$$

Onde o KPI indica a energia gasta [Gcal/tHC] no forno para craquear o HC e o V

HC, indica a vazão de entrada de nafta no forno [t/h]. O KPI utilizado tem por objetivo a serem minimizados, pois mede a energia gasta para realizar o craqueamento.

De posse dos dados, as variáveis são divididas em cinco blocos, com o objetivo de atribuir diferentes pesos a cada bloco e as variáveis presentes neles. A divisão é utilizada permite que o modelo estatístico possa considerar as variáveis já conhecidas com uma importância mais alta, facilitando a análise do KPI. Assim, a variável KPI é atribuída ao bloco correspondente (denominado por KPI), enquanto as variáveis manipuláveis no processo, como vazão de HC, VD/HC, COT, tiragem, temperatura de entrada do HC e abertura do damper, são alocadas em um bloco (denominado por Manipulada). Também é considerado o bloco (denominado por MP) onde é inserido as variáveis relacionadas ao parâmetro de matéria-prima, além de outro bloco (denominado por Menor Peso) com variáveis utilizadas para cálculos, como Cterm e densidade do gás combustível. As demais variáveis relevantes são agrupadas em um bloco adicional (denominado por Var Chaves). Com essa organização, o modelo pode avaliar de forma eficaz a importância de cada variável e observar o KPI adequadamente.

Para a modelagem do forno, foi utilizada a ferramenta de matemática estatística *Aspen ProMV*, na qual foram inseridos os dados do processo. Ao todo, foram inseridas 11.665 variáveis para realizar a modelagem. Os dados foram importados de uma planilha Excel para o software, e, conforme mencionado anteriormente, foi feita a divisão dos blocos. A Figura 6 apresenta a visualização dos dados importados, com a divisão dos blocos dentro do software.




Figura 6: Dados importados para o Aspen ProMV.

O software atribui um peso igual a todas as variáveis e blocos, mas também permite a definição de novos pesos. Dessa forma, é possível criar um modelo que dê maior atenção às variáveis mais importantes. A Quadro 2 apresenta os pesos utilizados na criação do modelo.

Bloco	Peso do Bloco	Variável	Peso da Variável
KPI	1	CTerm/ VNafta	1
Manipulada	1	V Nafta	1
Manipulada		VD/HC	1
Manipulada		COT	1
Manipulada		Tiragem	1
Manipulada		Tin Nafta NPH	1
Manipulada		Damper VT	1
Var Chaves	0,8	Dias Campanha	1
Var Chaves		T Chaminé	0,5
Var Chaves		T VD	0,5
Var Chaves		V VD	1
Var Chaves		CIT	1
Var Chaves		V GC	1
Var Chaves		O2	1
Var Chaves		PCI	0,0001
Var Chaves		Pressão de entrada Nafta NPH	0,5
Var Chaves		Pressão de entrada VD	0,5
Var Chaves		Pressão de entrada Rad	0,3
MP	1	PARAFINICIDADE (n-P+i-P)	1
Menor Peso	0,001	CTerm	0,0001
Menor Peso		Den GC	0,0001

Quadro 2: Divisão dos pesos dos blocos e variáveis.

A escolha dos pesos foi baseada na possibilidade de influenciar as variáveis quando o modelo indicar que alguma delas está impactando a eficiência do forno. As variáveis presentes no bloco Menor Peso foram utilizadas apenas para o cálculo do KPI, razão pela qual receberam um peso baixo no modelo. As variáveis presentes no bloco Manipuladas, que são aquelas de entrada do processo, e o KPI, o que é o principal interesse, receberam um peso maior. Já o bloco Var Chaves inclui as variáveis que respondem às variáveis do bloco Manipuladas, ou seja, não podem ser ajustadas diretamente. Por essa razão, elas recebem um peso menor no modelo.

De posse dos dados com os seus respectivos pesos, é possível gerar gráficos que mostram os dados de cada variável ao longo do tempo, os dados fora dos padrões normais

de operação, são excluídos, pois interferem no modelo e podem terem sido fruto de erros de medição, como mostra a Figura 7, onde é possível observar os dados selecionados (em vermelho) estão fora do padrão, logo, são excluídos.




Figura 7: Variação do KPI ao longo do tempo.

A variável que não apresentar dados fora do padrão, não tem nenhum dado excluído, como mostra a Figura 8, que representa a vazão de entrada de nafta no forno ao longo do tempo.




Figura 8: Variação da vazão de nafta ao longo do tempo.

A temperatura do VD teve muitos dados apresentando uma temperatura de 0°C (como mostra a Figura 9), o que não é possível fenomenologicamente com o forno em operação, logo foi possível verificar que o instrumento utilizado para a medição não estava confiável, tornando necessário a exclusão dessa variável do modelo.




Figura 9: Variação da temperatura do VD ao longo do tempo.

Após a limpeza e a confirmação da confiabilidade dos dados, é necessário a verificação dos parâmetros SPE e *Hotelling* T^2 (HT2), citados nas seções 2.7.2 e 2.7.3. O modelo é considerado bom quando o SPE indica valores menores que 2 e o HT2 indica valores menores que 40. Na figura 10, é possível verificar que alguns dados estão com valores de HT2 acima de 40, por tanto, necessitam ser excluídos.




Figura 10: Visualização do modelo nos parâmetros SPE e HT2.

Com os dados dentro dos parâmetros previamente definidos, o próximo passo foi selecionar os dados com o melhor KPI e excluir os demais. Para realizar essa divisão, foi gerado um gráfico com os dois principais componentes T[1] e T[2], no qual os dados foram agrupados em 80 categorias diferentes de KPI. Isso possibilitou uma análise visual,

permitindo identificar claramente os dados com melhor desempenho. Com base nessa visualização, foi possível selecionar os 26,29% melhores dados e excluir o restante, como mostra a Figura 11.




Figura 11: Visualização das categorias diferentes de KPI.

4 Resultados e Discussões

Após a conclusão da etapa de tratamento dos dados é possível verificar pelos parâmetros *Hotelling T²* e SPE que os dados do modelo estão bem ajustados ao modelo de PCA e não apresentam anomalias ou comportamentos fora do padrão, como mostra a Figura 12.




Figura 12: Visualização dos dados nos parâmetros HT2 e SPE.

Além disso, é possível observar que seis componentes principais são suficientes para explicar a variabilidade dos dados. Isso é indicado pela pontuação acumulada do coeficiente de determinação (R^2), que reflete a qualidade do ajuste do modelo aos dados de treinamento. No caso, o valor de R^2 foi de 92,45%, o que significa que o modelo conseguiu explicar grande parte da variabilidade dos dados de treinamento, ou seja, a maior parte da variação nos dados foi capturada pelos componentes principais selecionados.

A pontuação acumulada do Q^2 , por sua vez, mede a capacidade preditiva do modelo, ou seja, sua habilidade de prever os dados de um conjunto de teste, que não foi utilizado durante o treinamento. O valor de 92,43% para o Q^2 indica que o modelo tem uma excelente capacidade de generalização, sendo capaz de prever dados novos com uma precisão quase equivalente à que foi obtida nos dados de treinamento. Isso sugere que o modelo não apenas se ajustou bem aos dados existentes, mas também é eficaz para prever comportamentos futuros ou dados fora do conjunto de treinamento, o que é um indicativo de que o modelo tem boa robustez e não sofreu de overfitting (ajuste excessivo aos dados de treinamento), como mostra a Figura 13.




Figura 13: Pontuação acumulativas dos Q^2 e R^2 .

Com 7 componentes principais o aumento do Q^2 e R^2 foi inferior a 3%. Isso indica que a adição de um componente extra não trouxe uma melhoria significativa no desempenho do modelo. Com base nisso, com os seis componentes principais, o modelo apresenta um ótimo desempenho tanto em termos de ajuste aos dados de treinamento quanto de capacidade preditiva sobre dados não vistos, o que garante sua eficácia para aplicações práticas.

Além da pontuação acumulativa do modelo, ao analisar a pontuação do R^2 de cada variável individualmente, é possível observar que o modelo também representa bem as variáveis. Isso é evidenciado pelo fato de que o R^2 de cada variável ficou acima de 85%, indicando que o modelo consegue explicar de forma consistente a variabilidade das variáveis envolvidas. Esse resultado reforça a qualidade do ajuste do modelo e sua capacidade de capturar as principais relações entre as variáveis, tornando-o robusto e adequado para previsões e análises. Como mostra a Figura 15 e a Quadro 3.




Figura 15: Variável KPI ajustada ao modelo.

Número de Componentes Principais		6
Bloco	Variável	R^2
KPI	CTerm/V Nafta	0,9993
Manipulada	V Nafta	0,9686
Manipulada	VD/HC	0,9917
Manipulada	COT	0,9125
Manipulada	Tiragem	0,8575
Manipulada	Tin Nafta NPH	0,9339
Manipulada	Damper	0,9531

Quadro 3: R^2 de cada variável.

Com o modelo ajustado e representando o processo do forno de nafta, é possível identificar quais variáveis contribuem para aumentar a eficiência do craqueamento, como mostrado na Figura 16. A figura apresenta as variáveis que têm maior influência no desempenho do processo, permitindo observar as relações entre elas e a eficiência do craqueamento.




Figura 16: Variáveis que contribuem para a eficiência do forno.

No aspecto relacionado à convecção, o modelo indicou que a abertura do *Damper* exerce uma forte influência na eficiência do processo. Quanto mais fechado o *Damper*, maior a eficiência, pois ele controla a tiragem e o excesso de ar (medido pelo teor de oxigênio presente no forno). Com o *Damper* mais fechado, há uma maior retenção de calor, aumentando a eficiência do craqueamento. No entanto, quando o *Damper* está muito aberto, há um aumento na tiragem e no excesso de ar, o que pode reduzir a eficiência. Por outro lado, se o *Damper* for mantido excessivamente fechado, pode haver falta de oxigênio, prejudicando o processo.

Entretanto, ao verificar as condições de operação no campo, foi possível observar que as bancadas da convecção estavam sujas externamente devido ao acúmulo de resíduos da massa usada nos tijolos refratários da radiação. Esse acúmulo reduz a eficiência da troca térmica entre a carga entrando nas tubulações na convecção e os gases saindo da radiação. Como resultado, é necessário aumentar a quantidade de gases de combustão para vaporizar a carga antes de ela atingir a radiação, o que impacta negativamente a eficiência do processo.

Além disso, o modelo mostrou que, à medida que a carga aumenta, o *Damper* tende a fechar, isso ocorre porque o volume maior de carga a ser vaporizada exige uma maior quantidade de gases de combustão para garantir a vaporização adequada antes de a carga chegar à área de radiação. O modelo também mostrou que a diminuição da razão

VD/HC, faz com que não perca tanto calor para o VD, porém isso ao longo prazo pode aumentar a formação de coque e diminuir o tempo de campanha de operação do forno.

5 Conclusão

O modelo offline representou bem o comportamento do forno de pirólise de nafta, mostrando-se eficiente tanto no ajuste dos dados quanto na previsão de comportamentos futuros, trazendo as variáveis que impactam na eficiência do craqueamento, como abertura do *Damper*. Para trabalhos futuros seria possível exportar esse modelo para o *AspenOne* e utilizar de forma on-line, onde o engenheiro pode acompanhar em tempo real se o forno está operando dentro da zona boa e se não estiver, pode verificar qual variável está influenciando, o que torna possível atuar de forma direta na variável e melhorar a eficiência do seu processo.

Referências

- ABIPLAST. **Indústria brasileira de transformação de material plástico**. Perfil 2012. Disponível em: < <https://www.sindiplasba.org.br/perfil2012.pdf>>. Acesso em: Agosto de 2024.
- AGARWAL, Aman. **Machine Learning and Multivariate Statistics for Optimizing Bioprocessing and Polyolefin Manufacturing**. 2022.
- BARAZANDEH, Kazem et al. **Investigation of coil outlet temperature effect on the performance of naphtha cracking furnace**. Chemical Engineering Research and Design, v. 94, p. 307-316, 2015.
- BENINCA, Marcelo. **Integração energética de uma planta de eteno com aspectos de flexibilidade: Aplicação da Análise Pinch em conjunto com a otimização matemática**. 2008.
- BRITTO, Rodrigo da Silva et al. **Detecção de falhas com PCA e PLS aplicados a uma planta didática**. 2014.
- BUENO, Admar Jorge Machado. **ESTUDO DAS PERDAS ENERGÉTICAS NA SUPERFÍCIE DA RADIAÇÃO NOS FORNOS DE PIRÓLISE**. Universidade Federal do Rio de Janeiro, 2016.
- BURDEN, R. L.; FAIRES, J. D. **Numerical Analysis**. 9. ed. Boston, Massachusetts: Brooks/Cole, Cengage Learning, 2010;
- COSTA, Amanda de Carvalho. **Metodologia para Aumento da Vida útil de Serpentina de Fornos de Pirólise de Uma Unidade de Produção de Olefinas Leves**. Universidade Federal do Rio de Janeiro, 2019.
- CONZ, V. **Desenvolvimento de Analisadores Virtuais Aplicados a Colunas de Destilação Industriais**, Dissertação (mestrado) – Programa de Pós-Graduação em Engenharia Química, Departamento de Engenharia Química, Escola de Engenharia, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2005.
- GOMES, Gabriel; DVORSAK, Peter; HEIL, Tatiana Boavista Barros. **Indústria petroquímica brasileira: situação atual e perspectivas**. 2005. Disponível em: <https://web.bndes.gov.br/bib/jspui/bitstream/1408/2485/1/BS%2021%20Ind%c3%bastria%20petroqu%c3%admica%20brasileira_P.pdf>. Acesso em: Agosto de 2024.
- HOTELLING, H. (1933). **Analysis of a large dimensionality data set with applications to research on the ozone layer**. Journal of Educational Psychology, 24(3), 192-201.
- HUGENTHOBLE, M. W. **Integração energética de uma planta petroquímica de aromáticos através da técnica de Sítio Total**. 2020. Dissertação (Mestrado em Engenharia Química) – Universidade Federal do Rio Grande do Sul. Programa de Pós-graduação em Engenharia Química, Porto Alegre, 2020. Disponível em: <https://www.lume.ufrgs.br/bitstream/handle/10183/212461/001116471.pdf?sequence=1&isAllowed=y>. Acesso em: Setembro/2020.
- JOHNSON, R. A., & Wichern, D. W. (2007). **Applied Multivariate Statistical Analysis** (6th ed.). Pearson Prentice Hall.
- JOLLIFFE, I. T. (2002). **Principal Component Analysis** (2nd ed.). Springer.

LEITE L. F. **Olefinas Leves: Tecnologia, Mercado e Aspectos Econômicos**. Rio de Janeiro: Interciência, 2013. pp. 4; 21-59.

LOESCH, Claudio; HOELTGEBAUM, Marianne. **Métodos estatísticos multivariados**. Saraiva Educação SA, 2017.

LUMMUS. **Ethylene Furnace Training Course, Terminology**. Bloomfield, New Jersey, 2010.

NÓBREGA, Maria Bianca Medeiros de Mello. **Otimização de um processo real de destilação atmosférica de petróleo utilizando simulação de processos e métodos estatísticos**. 2018. Dissertação de Mestrado. Brasil.


REBORDINOS, Jesús González et al. **Evaluation of retrofitting of an industrial steam cracking furnace by means of CFD simulations**. *Applied Thermal Engineering*, v. 162, p. 114206, 2019.

SHLENS, Jonathon. **A tutorial on principal component analysis**. arXiv preprint arXiv:1404.1100, 2014.


SILVA, J. L. **Modelagem e simulação de reatores autoclave para produção de PEBD**. 2012. Dissertação (Mestrado em Engenharia, Programa De Pós-Graduação Em Engenharia Química) (Área de Concentração: Modelagem e Simulação de Processos) - Departamento de Engenharia Química, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2012;

SOLEDAR, L. **Desenvolvimento de modelo para a previsão do tempo de campanha de um forno de craqueamento de etano**, Dissertação de Mestrado, Programa de Pós Graduação em Engenharia Química, UFRGS, 2015.


Anexo 1 - Variação do VD/HC ao longo do tempo.




Anexo 2 - Variação da COT ao longo do tempo.




Anexo 3 - Variação da Tiragem ao longo do tempo.




Anexo 4 - Variação da abertura do Damper ao longo do tempo.




Anexo 5 - Variação da temperatura de entrada da Nafta ao longo do tempo.




Anexo 6 - Variação da temperatura da chaminé ao longo do tempo.




Anexo 8 - Variação da vazão do VD ao longo do tempo.




Anexo 9 - Variação da CIT ao longo do tempo.




Anexo 10 - Variação da vazão do GC ao longo do tempo.




Anexo 11 - Variação do teor do O2 ao longo do tempo.




Anexo 12 - Variação do PCI ao longo do tempo.




Anexo 13 - Variação da pressão de entrada da nafta no forno ao longo do tempo.




Anexo 14 - Variação da pressão de entrada do VD no forno ao longo do tempo.




Anexo 15 - Variação da pressão de entrada da mistura na zona radiação longo do tempo.




Anexo 16 – Variação da Parafinicidade ao longo do tempo.




Anexo 17 - Variação da Cterm ao longo do tempo.




Anexo 18 - Variação da Densidade do gás combustível ao longo do tempo.



Anexo 19 - Seleção dos 26,29% dos dados bons.



Anexo 20 - Seleção dos dados não tão bons para a exclusão.



Anexo 21 – Variáveis importante para a eficiência do forno.

	X-Space	range	Cont. Scores [1 - 2]
1	Damper VT	7	-0,10023634046
2	VD/HC	3	-0,068259633042
3	O2	13	-0,0605832859722
4	CTerm/V Nafta	1	-0,0325363062868
5	Tiragem	5	-0,00994281114341
6	V VD	10	-0,00597358126213
7	PARAFINICIDA...	18	-0,00398323997291
8	T Chaminé	9	-0,00267275560477
9	Pin Nafta NPH	15	-0,00209300449992
10	Dens GC	20	-1,18472183161e-16
11	CTerm	19	5,51648231076e-16
12	PCI	14	7,39442574629e-11
13	Tin Nafta NPH	6	0,000366119057886
14	Dias Campanha	8	0,00194401593021
15	Pin Rad	17	0,00206350000338
16	Pin VD	16	0,00538641176696
17	COT	4	0,0213963380919
18	V GC	12	0,0323390718927
19	CIT	11	0,041453165379
20	V Nafta	2	0,0659663995439