

**UNIVERSIDADE FEDERAL DE SÃO CARLOS
CENTRO DE CIÊNCIAS EXATAS E DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA QUÍMICA**

MATHEUS HENRIQUE CANDIDO TORRES

**ESTUDO DE CURVAS DE PENALIDADE PARA CONTROLE DE
PROCESSOS APLICADO À COGERAÇÃO DE UMA PLANTA
SUCROALCOOLEIRA**

**SÃO CARLOS
2025**

MATHEUS HENRIQUE CANDIDO TORRES

ESTUDO DE CURVAS DE PENALIDADE PARA CONTROLE DE
PROCESSOS APLICADO À COGERAÇÃO DE UMA PLANTA
SUCROALCOOLEIRA

Trabalho de conclusão de curso apresentado ao Departamento de Engenharia Química da Universidade Federal de São Carlos, como requisito para obtenção do título de bacharel em Engenharia Química.

Orientador: Prof. Dr. Felipe Fernando Furlan

SÃO CARLOS

2025

ESTUDO DE CURVAS DE PENALIDADE PARA CONTROLE DE PROCESSOS
APLICADO À COGERAÇÃO DE UMA PLANTA SUCROALCOOLEIRA

Trabalho de conclusão de curso apresentado à
Universidade Federal de São Carlos - UFSCar,
para obtenção do título de bacharel em Engenharia
Química.

Aprovado em 17 de fevereiro de 2025.

BANCA EXAMINADORA

Prof.º Dr. Felipe Fernando Furlan
Orientador – UFSCar

Me. Gabriel Baioni e Silva
Convidado

Prof.º Dr. José Maria Corrêa Bueno
Professor da disciplina - UFSCar

AGRADECIMENTOS

Agradeço primeiramente a DEUS por estar comigo durante minha jornada acadêmica, direcionando-me, ensinando-me, apoiando-me em todos os momentos e ajudando-me a vencer cada dificuldade, sendo minha fortaleza.

À minha mãe Eliane e ao meu pai Antônio Marcos, por me apoiarem na mudança de cidade para investir em meus sonhos, sustentando-me e apoiando-me em todos os momentos, acompanhando-me em cada passo dado, com amor incondicional.

Às minhas irmãs Maira e Mainé, por sempre me ajudarem, me escutarem nos momentos difíceis e celebrarem comigo os momentos felizes.

Aos meus avós, tios e primos, que sempre me incentivaram a ser a minha melhor versão.

Aos meus amigos de Santa Bárbara d'Oeste, que, apesar da distância, me acompanharam nesta trajetória, sempre me animando. Em especial, agradeço ao Guilherme por sempre orar por mim.

Aos amigos João Gaudencio, Rogério e José que DEUS colocou em meu caminho no início da graduação, acolhendo-me e apoiando-me ao longo de minha jornada acadêmica.

Aos meus amigos Marcos, Henrique, Dennis e Adilson, por me ajudarem e animarem todos os dias neste período final da graduação.

Aos professores e colegas de curso, que me inspiraram e ajudaram a crescer e me desenvolver. Em especial, ao professor João Batista, que me orientou no início da graduação, e ao professor Felipe Furlan, que me orientou neste trabalho.

Agradeço também ao Gabriel e ao professor José Maria, que, junto ao professor Felipe, compõem esta banca examinadora.

Por fim, gostaria de agradecer aos meus amigos Carlos, Eduardo e Fernando, por todo o apoio e aprendizado em minha carreira profissional.

Se cheguei até aqui, foi graças ao apoio de todos vocês. Muito obrigado!

RESUMO

Na cogeração de plantas sucroalcooleiras, gera-se vapor nas caldeiras a partir do calor da combustão do bagaço da cana-de-açúcar para suprir demandas variáveis de acionamentos e aquecimentos em equipamentos do processo, simultaneamente à produção de energia elétrica pelo rebaixamento do vapor em turbogeradores. O sistema de cogeração sofre diversas perturbações decorrentes de variações nas demandas das utilidades ou no suprimento do vapor de alta pressão pela caldeira. Nessas situações, deve-se priorizar as demandas críticas à operação da fábrica com a máxima eficiência energética. Em muitos casos, já existe um sistema supervisório que sugere ajustes nas vazões das várias linhas de vapor de modo a manter o suprimento dos vapores de processo, comumente através de controladores PID, um sistema com uma entrada e uma saída para controlar um sistema multivariável. Neste contexto, foi proposto um método de sintonia periódica de controladores, comparando controladores proporcionais e proporcionais-integrais, de uma cogeração, com o objetivo de melhorar a estabilidade nas linhas de vapor e maximizar a eficiência energética. Foram testados dois algoritmos de otimização, para a sintonia dos ganhos proporcionais e integrais, o BFGS e o SLSQP, aplicados a uma função objetivo que avalia a soma do desvio do *set point* nas pressões das linhas de vapor e na produção excedente de energia. Observou-se que o melhor ajuste foi obtido para o método SLSQP, impondo restrições nos valores máximos e mínimos dos ganhos proporcionais e integrais, considerando um horizonte de otimização de 40 segundos. Foram testadas duas funções para a penalização da energia exportada, quadrática e linear, na qual a função quadrática obteve maior exportação de energia elétrica, porém com um maior desvio dos *set points* de pressão. De modo geral, o controle demonstrou robustez para corrigir as perturbações e otimizar a geração de energia elétrica.

Palavras chaves: Controle de processos, Função penalidade, Otimização de processos, Cogeração, Turbogenerador, Geração de vapor.

LISTA DE FIGURAS

Figura 1 - Ciclo Rankine.....	12
Figura 2 - Diagrama Pressão por Entalpia da água	13
Figura 3 – Diagrama P&ID do processo de cogeração.....	23
Figura 4 – Simulação com controlador P e otimização por BFGS avaliando 40 segundos.....	31
Figura 5 – Simulação com controlador P e otimização por BFGS avaliando 20 segundos.....	31
Figura 6 – Simulação com controlador P e otimização por BFGS avaliando 10 segundos.....	31
Figura 7 – Simulação com controlador P e otimização por BFGS avaliando 5 segundos.....	32
Figura 8 – Simulação com controlador PI e otimização por BFGS avaliando 40 segundos.....	32
Figura 9 – Simulação com controlador PI e otimização por BFGS avaliando 20 segundos.....	33
Figura 10 – Simulação com controlador PI e otimização por BFGS avaliando 10 segundos.....	33
Figura 11 – Simulação com controlador PI e otimização por BFGS avaliando 5 segundos.....	33
Figura 12 – Simulação com controlador PI e otimização por BFGS avaliando 80 segundos.....	35
Figura 13 – Simulação com controlador PI e otimização por BFGS avaliando 40 segundos.....	35
Figura 14 – Simulação com controlador PI e otimização por BFGS avaliando 20 segundos.....	36
Figura 15 – Simulação com controlador PI e otimização por BFGS avaliando 10 segundos.....	36
Figura 16 – Simulação com controlador PI e otimização por BFGS avaliando 5 segundos.....	36
Figura 17 – Cenário de simulação com distúrbios nos consumidores de vapor do processo.....	38
Figura 18 – Simulação com controlador PI e otimização por BFGS avaliando 40 segundos.....	38

Figura 19 – Simulação com controlador PI e otimização por BFGS avaliando 10 segundos.....	38
Figura 20 – Cenário de simulação com distúrbio no consumidor de vapor de 2,5 bar do processo.....	39
Figura 21 - Simulação com controlador PI e otimização por BFGS sem restrição avaliando 10 segundos.	40
Figura 22 - Simulação com controlador PI e otimização por BFGS sem restrição avaliando 10 segundos.	40
Figura 23 - Simulação com controlador PI e otimização por SLSQP sem restrição avaliando 10 segundos.	40
Figura 24 - Simulação com controlador PI e otimização por SLSQP sem restrição avaliando 10 segundos.	41
Figura 25 - Simulação com controlador PI e otimização por SLSQP com restrição avaliando 10 segundos.	41
Figura 26 - Simulação com controlador PI e otimização por SLSQP com restrição avaliando 10 segundos.	42
Figura 27 - Simulação com controlador PI e otimização por SLSQP com restrição avaliando 40 segundos.	43
Figura 28 - Simulação com controlador PI e otimização por SLSQP com restrição avaliando 40 segundos.	43
Figura 29 – Cenário de simulação com distúrbio no consumidor de vapor de 2,5 bar do processo.....	45
Figura 30 - Simulação com controlador PI e otimização por SLSQP com restrição avaliando 40 segundos e penalidade quadrática da exportação.....	46
Figura 31 - Simulação com controlador PI e otimização por SLSQP com restrição avaliando 40 segundos e penalidade quadrática da exportação.....	46
Figura 32 - Simulação com controlador PI e otimização por SLSQP com restrição avaliando 40 segundos e penalidade linear da exportação.....	46
Figura 33 - Simulação com controlador PI e otimização por SLSQP com restrição avaliando 40 segundos e penalidade linear da exportação.....	47

NOMENCLATURAS E ABREVIACOES

PV	Variável de processo
SP	<i>Set point</i>
MV	Variável manipulada
<i>Overshot</i>	Quando a variável controlada ultrapassa o <i>set point</i>
<i>Offset</i>	Quando uma diferença entre a variável controlada e o <i>set point</i> permanecem
<i>Hunting</i>	Quando a variável controlada permanece oscilando ao redor do <i>set point</i>
H	Horizonte de simulação, intervalo de tempo da simulação em que o algoritmo de otimização é aplicado
P	Controlador proporcional
PI	Controlador proporcional-integral
PID	Controlador proporcional-integral-derivativo
m	Vazão mássica de vapor
TG	Turbogerador
Cald	Caldeira
Reb	Válvula rebaixadora
Cons	Equipamentos do processo que consomem vapor da linha
<i>SISO</i>	Sistemas ou controladores com uma variável de entrada e uma variável de saída
<i>MIMO</i>	Sistemas ou controladores com mais de uma variável de entrada e mais de uma variável de saída

SUMÁRIO

1.	INTRODUÇÃO	10
2.	REVISÃO DE LITERATURA	11
2.1.	CICLOS RANKINE.....	11
2.2.	EQUAÇÕES DE ESTADO	12
2.2.1.	EQUAÇÃO DE ESTADO DE PENG-ROBINSON.....	13
2.3.	COGERAÇÃO DE ENERGIA ELÉTRICA EM USINAS	14
2.4.	CONTROLADOR PID	15
2.5.	ALGORÍTMOS DE OTIMIZAÇÃO	16
2.5.1.	OTIMIZAÇÃO POR CAMINHO VIÁVEL	17
2.5.2.	MÉTODO NELDER-MEAD.....	17
2.5.3.	ALGORITMO BFGS	19
2.5.4.	ALGORITMO SLSQP.....	20
3.	METODOLOGIA.....	21
3.1.	PYTHON	21
3.1.1.	SCIPY <i>MINIMIZE</i>	21
3.1.2.	COOL PROP	22
3.2.	DESCRIÇÃO DO PROCESSO	22
3.3.	ESTRATÉGIA DE CONTROLE	23
3.4.	MODELAGEM MATEMÁTICA DO PROCESSO	24
3.5.	FUNÇÃO OBJETIVO	27
3.6.	ESTUDO DE CASO	28
4.	RESULTADOS	30
4.1.	COMPARAÇÃO ENTRE CONTROLES P E PI.....	30
4.2.	AVALIAÇÃO DO EFEITO DO HORIZONTE DE INTEGRAÇÃO	34
4.3.	COMPARAÇÃO DOS ALGORITMOS DE OTIMIZAÇÃO	39
4.4.	AJUSTANDO A PENALIDADE DA EXPORTAÇÃO.....	45

5. CONCLUSÃO	49
6. SUGESTÃO DE TRABALHOS FUTUROS	49
REFERÊNCIAS BIBLIOGRÁFICAS	51

1. INTRODUÇÃO

As usinas sucroenergéticas desempenham um papel fundamental na produção de produtos essenciais como açúcar, álcool, bagaço e energia elétrica. A operação dessas usinas está diretamente ligada às condições do mercado, uma vez que os preços dos produtos flutuam constantemente. Dessa forma, é imprescindível que a produção seja planejada de maneira estratégica para atender a contratos previamente estabelecidos e, simultaneamente, maximizar a rentabilidade da usina (BOBROFF-MALU e SÁNCHEZ, 2015).

No entanto, o processo está sujeito a diversas perturbações que podem desviar seus parâmetros das condições operacionais ideais. Para garantir que a produção permaneça dentro das especificações desejadas e que a eficiência seja mantida, torna-se necessário adotar estratégias de controle de processo capazes de corrigir tais distúrbios e conduzir o sistema a uma nova condição ótima de operação.

Nas usinas, controladores PID (Proporcional, Integral e Derivativo) estão amplamente disponíveis para o controle dos processos industriais. No entanto, esses controladores, por si só, não são suficientes para garantir uma operação otimizada, especialmente em um sistema dinâmico, multivariável e sujeito a diversos distúrbios. Assim, torna-se necessário o desenvolvimento de estratégias que permitam a otimização da operação, de modo a integrar a estratégia de controle e aprimorar o desempenho do sistema de cogeração (JUNEJA, 2020).

Os controladores PID podem ser sintonizados manualmente ou através de algoritmos para se adaptarem ao processo. Uma desvantagem dos controladores PID é seu comportamento SISO (Single Input and Single Output) em sistemas de controle com múltiplas variáveis, nestes cenários, controladores PID em cascata são utilizados para acoplar mais que uma variável, os quais podem apresentar um comportamento superior à sua atuação de forma individual (JUNEJA, 2020).

Os algoritmos de otimização são capazes de escolher os melhores parâmetros de um controlador PID, caso a função objetivo seja representativa ao desempenho do controle no processo, podendo realizar automaticamente a sintonia do controlador. Uma função objetivo representativa, demandaria quantificar a performance do processo no futuro, o que pode ser feito através de uma simulação dinâmica do processo (JUNEJA, 2020).

Simulações de processos simples e com poucos distúrbios aleatórios apresentam resultados melhores que as simulações em processos mais complexos, além disso, a representatividade da simulação dinâmica diminui com o aumento do tempo da simulação, sendo necessário investigar a precisão do modelo simulado com o processo real no tempo. Este modelo vinculado a uma função objetivo representativa com o objetivo, viabilizaria a aplicação de algoritmos de otimização para auto sintonia dos parâmetros do controlador PID (JUNEJA, 2020).

Neste sentido, a função objetivo precisará pontuar o desempenho de cada variável controlada, como também combinar as pontuações, de forma que o algoritmo de otimização possa identificar a melhor direção para otimizar cada parâmetro dos controladores PID, com o intuito de aumentar a proximidade das pressões em cada linha de vapor com o seu respectivo *set point*, enquanto maximiza a exportação de energia elétrica. Assim, os controladores PID podem operar de forma orquestrada, de modo a extrair maiores ganhos operacionais do processo.

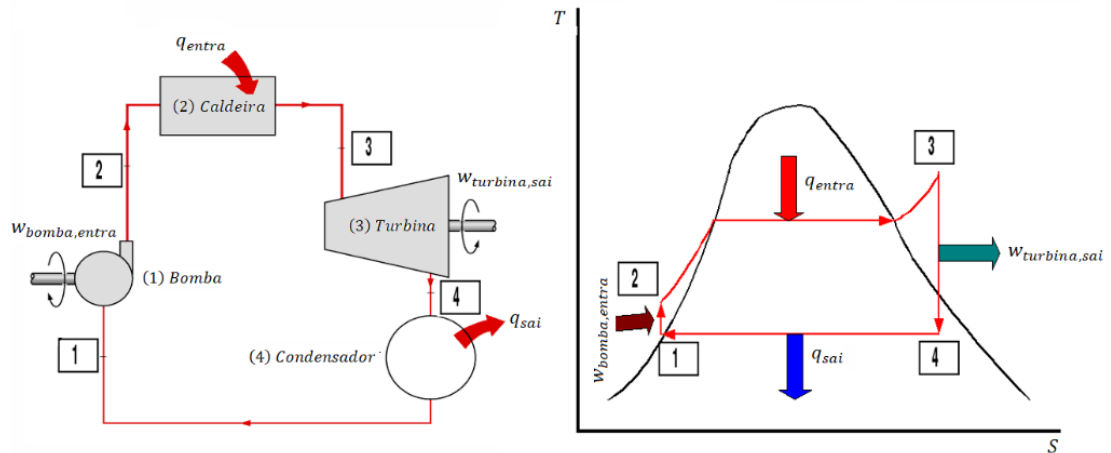
2. REVISÃO DE LITERATURA

2.1. CICLOS RANKINE

O Ciclo Rankine é um ciclo termodinâmico amplamente utilizado na geração de energia elétrica, sendo a base de operação de diversas plantas termoelétricas, incluindo as usinas sucroalcooleiras. Esse ciclo se destaca pela conversão eficiente da energia térmica contida no vapor de água em trabalho mecânico, que posteriormente é convertido em eletricidade por meio de turbogeradores (BORGNAKKE e SONNTAG, 2018).

O funcionamento do Ciclo Rankine ocorre por meio de quatro etapas principais, mostradas na figura 1, sendo elas: A compressão do fluido de trabalho em uma bomba, o aquecimento em uma caldeira até a conversão em vapor, a expansão do vapor em uma turbina para a geração de trabalho mecânico e a condensação do vapor para reinício do ciclo. Esse processo permite um aproveitamento eficiente da energia térmica disponível, sendo fundamental para diversas aplicações industriais e de geração de energia (OLIVEIRA, 2024).

Figura 1 - Ciclo Rankine.



Fonte: Rubens Oliveira, 2024.

A importância do Ciclo Rankine na geração de energia nas usinas sucroalcooleiras está associada à sua capacidade de aproveitar um subproduto da produção de açúcar e etanol, o bagaço, contribuindo para a sustentabilidade e eficiência energética do setor. Além disso, esse processo permite a autossuficiência energética da usina e a comercialização do excedente de eletricidade para a rede elétrica (BOBROFF-MALU e SÁNCHEZ, 2015).


2.2. EQUAÇÕES DE ESTADO

As equações de estado são relações matemáticas que descrevem o comportamento termodinâmico de um sistema com base em parâmetros como a pressão, o volume e a temperatura. Elas são fundamentais para calcular propriedades como a entalpia, a entropia e o coeficiente de compressibilidade de um fluido. As equações de estado podem ser classificadas em dois grupos principais: empíricas e fundamentais. As empíricas são baseadas em dados experimentais, enquanto as fundamentais buscam derivar suas relações a partir de princípios termodinâmicos básicos (SMITH et al., 2019).

Existem várias equações de estado, cada uma com seu grau de complexidade e aplicabilidade, dependendo do tipo de substância e das condições operacionais. Entre as mais conhecidas e utilizadas na engenharia química, destacam-se a Equação de Van der Waals, a Redlich-Kwong, a Soave-Redlich-Kwong e, principalmente, a Equação de Peng-Robinson, que tem grande relevância no estudo e na simulação de sistemas multifásicos, como os encontrados em processos de separação e reações

químicas. A figura 2 apresenta um exemplo de diagrama que relaciona a pressão com a entalpia de um sistema contendo água pura (SMITH et al., 2019).

Figura 2 - Diagrama Pressão por Entalpia da água



Fonte: Autoria própria com o uso da biblioteca *CoolProp*.

Embora várias equações de estado tenham sido desenvolvidas ao longo do tempo, a escolha da equação mais adequada depende das características do sistema em questão, como o tipo de fluido (ideal ou real), a faixa de temperatura e pressão, e a necessidade de precisão nos cálculos (SMITH et al., 2019).

2.2.1. EQUAÇÃO DE ESTADO DE PENG-ROBINSON

A equação de estado de Peng-Robinson (PR), proposta por David Peng e Donald Robinson em 1976, é uma das mais utilizadas para modelar sistemas de gases e líquidos. Ela foi desenvolvida para fornecer uma descrição mais precisa do comportamento de fluidos reais em uma ampla faixa de condições termodinâmicas, especialmente em relação ao cálculo de propriedades críticas e à previsão de transições de fase, como a vaporização e a condensação (SOUSA, 2022).

A equação de Peng-Robinson é dada pela equação 1:

$$p = \frac{RT}{V_m - b} - \frac{a\alpha}{V_m^2 + 2bV_m - b^2} \quad (1)$$

Onde p é a pressão, T é a temperatura, V_m é o volume molar, R é a constante dos gases ideais, a e b são parâmetros específicos de cada substância e $\alpha(T)$ é uma

função de temperatura que permite ajustar o comportamento do fluido de acordo com as condições termodinâmicas (SOUSA, 2022).

Uma das principais vantagens da equação de Peng-Robinson é sua capacidade de fornecer uma boa descrição do comportamento termodinâmico de uma variedade de substâncias, incluindo gases não ideais e líquidos, com um número relativamente pequeno de parâmetros ajustáveis. Ela é particularmente útil em processos industriais como destilação, extração e processos de separação, sendo amplamente aplicada na engenharia química para prever o comportamento de misturas gasosas e líquidas em diversas condições operacionais (SMITH et al., 2019).

2.3. COGERAÇÃO DE ENERGIA ELÉTRICA EM USINAS

A cogeração é um processo de produção simultânea de eletricidade e calor útil a partir de uma única fonte de energia, sendo amplamente utilizado em usinas sucroalcooleiras. Nesses sistemas, a biomassa proveniente do bagaço de cana-de-açúcar é utilizada como combustível para a geração de vapor em caldeiras. O vapor gerado possui alta energia térmica e é direcionado para diversos acionamentos mecânicos e processos de aquecimento dentro da usina (ALVES, 2011).

O vapor de alta e média pressão são utilizados para acionar moendas, picadores e outros equipamentos, além de alimentar turbogeradores para a geração de eletricidade. Após a sua utilização em turbinas de expansão, o vapor rebaixado ainda pode ser aproveitado para suprir demandas térmicas do processo industrial, como aquecimento e evaporação, garantindo um uso eficiente da energia disponível (ALVES, 2011).

Outra opção disponível na cogeração para rebaixar o vapor são as válvulas rebaixadoras de vapor, que podem atuar com maior velocidade para corrigir distúrbios do processo, mas com a desvantagem de não gerar energia elétrica.

Esse modelo de cogeração torna a planta industrial autossuficiente, pois a energia gerada internamente é suficiente para suprir todas as suas necessidades operacionais, reduzindo a dependência de fontes externas de eletricidade. Além disso, em muitos casos, o excedente de energia produzido pode ser exportado para a rede elétrica, representando uma fonte adicional de receita para a usina (ALVES, 2011).

Dessa forma, a cogeração em usinas sucroalcooleiras não apenas maximiza o aproveitamento energético da biomassa, mas também contribui para a sustentabilidade do setor, reduzindo a emissão de gases de efeito estufa e

promovendo o uso racional dos recursos disponíveis (BOBROFF-MALU e SÁNCHEZ, 2015).

2.4. CONTROLADOR PID

Os controladores PID (Proporcional-Integral-Derivativo) são uma das ferramentas mais amplamente utilizadas no controle de processos industriais. Desenvolvidos no início do século XX, os primeiros estudos sobre esse tipo de controle remontam a 1911, com as pesquisas de Elmer Sperry. No entanto, a formulação moderna do controlador PID foi estabelecida por Nicolas Minorsky em 1922, quando estudava a estabilização de navios. Desde então, esse tipo de controlador tem sido aplicado em uma ampla variedade de sistemas industriais, garantindo maior estabilidade e precisão nos processos automáticos (WOJSZNIS e BLEVINS, 2013).

O controlador PID é composto por três componentes principais:

1. **Proporcional (P)**: Responsável pela resposta imediata ao erro do sistema. O controle proporcional multiplica o erro por um ganho, de forma que quanto maior o erro, maior será a ação de controle.
2. **Integral (I)**: Atua sobre o erro acumulado ao longo do tempo. O controle integral soma os erros passados e os multiplica por um ganho, eliminando erros persistentes e melhorando a precisão em regime permanente.
3. **Derivativo (D)**: Atua sobre a taxa de variação do erro, ou seja, sua derivação em relação ao tempo. Esse componente multiplica a variação do erro por um ganho, contribuindo para reduzir oscilações e melhorar a estabilidade do sistema.

A equação geral do controle PID é dada pela equação 2:

$$MV(t) = K_p e(t) + K_i \int_0^t e(\tau) d\tau + K_d \frac{de(t)}{dt} \quad (2)$$

Onde:

- K_p é o ganho proporcional
- K_i é o ganho integral
- K_d é o ganho derivativo
- e é o erro

- t é o tempo
- τ é o tempo de integração

Cada um desses componentes pode ser ajustado de forma independente para otimizar o desempenho do controlador conforme as características do processo a ser controlado (WOJSZNIS e BLEVINS, 2013).

Os controladores PID estão amplamente presentes nos Controladores Lógicos Programáveis (CLPs), que são dispositivos eletrônicos usados na automação industrial (JUNEJA, 2020). Os CLPs permitem a implementação de malhas de controle PID por meio de software, facilitando ajustes, monitoração e diagnóstico dos parâmetros de controle (FLACH, 2024). A integração de controladores PID em CLPs possibilita um controle mais eficiente de variáveis como temperatura, pressão, vazão e nível em processos industriais (JUNEJA, 2020).

A capacidade de ajustar automaticamente os parâmetros de controle permite uma resposta mais eficiente às perturbações do sistema, garantindo um funcionamento otimizado e reduzindo perdas e desperdícios (JUNEJA, 2020).

Dessa forma, os controladores PID desempenham um papel crucial na modernização da indústria, proporcionando maior confiabilidade e automação em diversos segmentos produtivos (BEQUETTE, 2023; ANG, 2005).

2.5. ALGORÍTMOS DE OTIMIZAÇÃO

Na engenharia química, a otimização desempenha um papel crucial no controle de processos industriais contínuos, onde o objetivo é maximizar a eficiência e minimizar os custos operacionais, respeitando uma série de restrições físicas e operacionais. A busca por soluções ótimas, que envolvem variáveis de controle como temperatura, pressão e vazão, exige o uso de algoritmos de otimização especializados para lidar com a complexidade e as características dinâmicas desses processos. A natureza não linear e multimodal dessas funções, bem como as limitações impostas pelos próprios sistemas, torna a otimização um desafio (JUNEJA, 2020).

Dentro deste contexto, a otimização por caminho viável surge como uma abordagem importante, permitindo que se busque a melhor solução dentro de um conjunto de soluções factíveis que atendem às restrições do processo (MA, 2024). Em paralelo, o algoritmo Nelder-Mead, uma técnica heurística baseada apenas em avaliações da função objetivo, oferece uma alternativa robusta para otimizar

processos em que as informações derivativas podem ser difíceis de obter ou não estão disponíveis (NELDER, 1965).

2.5.1. OTIMIZAÇÃO POR CAMINHO VIÁVEL

A otimização por caminho viável é uma abordagem fundamental em problemas de otimização matemática, caracterizada pela busca pela melhor solução dentro de um conjunto restrito de possibilidades. Em diversas áreas da ciência e engenharia, problemas de otimização frequentemente envolvem a maximização ou minimização de uma função objetivo, sujeita a um conjunto de restrições que definem o espaço viável onde as soluções devem ser buscadas. Nesse contexto, a otimização por caminho viável pode ser entendida como o processo de identificação da melhor solução dentro do conjunto de soluções factíveis, ou seja, aquelas que atendem às restrições impostas (MA, 2024).

Essa abordagem é frequentemente aplicada em problemas envolvendo controle ótimo, onde se busca uma política de controle que, ao longo do tempo, conduza o sistema ao melhor desempenho possível, levando em consideração as variáveis de controle disponíveis e as limitações do sistema. Em muitas situações, como em processos industriais, o número de possíveis trajetórias é infinitamente grande, o que exige o desenvolvimento de algoritmos sofisticados capazes de explorar o conjunto de soluções viáveis de forma eficiente e precisa (MA, 2024).

2.5.2. MÉTODO NELDER-MEAD

O algoritmo de otimização Nelder-Mead, também conhecido como método do simplex, é uma técnica amplamente utilizada em problemas de otimização não linear, especialmente quando a função objetivo é difícil de ser diferenciada ou possui comportamentos complexos, como descontinuidade, não linearidade ou multimodalidade. Desenvolvido por John Nelder e Roger Mead em 1965, o método é uma abordagem heurística de busca, que não requer informações das derivativas da função objetivo, ou seja, é um método de busca direta. Sua simplicidade e versatilidade o tornam uma ferramenta útil em diversos campos da ciência e engenharia, onde problemas de otimização de natureza não convexa são comuns (SCIPY; NELDER, 1965).

O algoritmo Nelder-Mead é uma técnica de otimização baseada em um processo iterativo que manipula um conjunto de pontos, conhecido como simplex, para explorar

e convergir para uma solução ótima. Um simplex em um espaço n-dimensional é uma figura geométrica composta por $n+1$ vértices, e o método opera na busca da solução ótima ajustando esses vértices com base nas avaliações da função objetivo (SCIPY; NELDER, 1965).

Ao contrário de métodos clássicos de otimização, como o gradiente descendente, que dependem das derivadas da função, o método de Nelder-Mead é um algoritmo baseado em avaliações de função. Ele é particularmente eficaz em problemas onde a função objetivo é complexa, difícil de diferenciar ou mesmo sem derivadas (SCIPY; NELDER, 1965).

O algoritmo Nelder-Mead começa com a seleção de um conjunto inicial de pontos (o simplex) e segue um ciclo iterativo de transformações para melhorar a solução, baseado em três operações principais (NELDER, 1965):

- **Reflexão:** O ponto com o pior valor da função objetivo é refletido em relação ao centro de massa dos outros pontos. O objetivo dessa operação é tentar encontrar uma solução que possua um valor melhor para a função objetivo.
- **Expansão:** Caso a reflexão resulte em uma solução melhor que a melhor solução atual, o simplex expande para explorar ainda mais essa direção, gerando um novo ponto.
- **Contração:** Se a reflexão não resulta em uma melhoria significativa, a operação de contração é aplicada para tentar aproximar os pontos em uma região mais promissora da solução.

Além disso, o algoritmo realiza uma redução do simplex, onde a distância entre todos os pontos e o melhor ponto é reduzida por um fator, aproximando todos esses pontos à região mais promissora, assegurando que o processo de busca continue em direção à solução ótima (SCIPY; NELDER, 1965).

Essas operações são realizadas de maneira iterativa até que o critério de convergência seja atingido, que pode ser baseado em uma tolerância pré-estabelecida para a melhoria das soluções ou para o tamanho do simplex (SCIPY; NELDER, 1965).

A importância do método de Nelder-Mead reside na sua simplicidade e robustez. Alguns dos principais benefícios que tornam esse algoritmo amplamente utilizado incluem:

- **Independência de Derivadas:** O método não requer o cálculo de derivadas da função objetivo, o que o torna ideal para problemas onde as derivadas são difíceis de calcular ou não existem.
- **Capacidade de lidar com funções não suaves e não lineares:** O Nelder-Mead é eficaz em otimizar funções que apresentam comportamentos não convencionais, como descontinuidade, não convexidade ou multimodalidade.
- **Aplicabilidade ampla:** Este algoritmo é utilizado em uma ampla gama de áreas, incluindo física, engenharia, economia, biologia computacional e otimização de processos industriais. Ele é particularmente útil em problemas com dimensões moderadas e funções de difícil modelagem.
- **Baixo custo computacional:** O algoritmo não exige grandes recursos computacionais em comparação com outros métodos de otimização, como aqueles baseados em derivadas ou métodos globais, tornando-o uma escolha viável para problemas com recursos limitados.

Apesar de suas vantagens, o algoritmo Nelder-Mead também possui algumas limitações. Por exemplo, ele pode ser ineficiente em problemas de alta dimensionalidade ou quando o simplex começa a se comportar de maneira degenerada, resultando em um processo de busca menos eficiente. Além disso, o algoritmo é uma heurística local e, portanto, pode ficar preso em ótimos locais, especialmente em problemas multimodais, sem garantir a obtenção do ótimo global (SCIPY; NELDER, 1965).

2.5.3. ALGORITMO BFGS

O BFGS (Broyden–Fletcher–Goldfarb–Shanno) é um algoritmo iterativo de otimização que pertence à família dos métodos quasi-Newton. Foi desenvolvido de forma independente por Roger Fletcher, Donald Goldfarb e Michael Shanno em 1970. Ele se baseia em uma aproximação da matriz Hessiana inversa (segunda derivada) para encontrar um ponto de mínimo ou máximo de uma função objetivo suave (SCIPY; NOCEDAL, 2006). Características principais:

- **Tipo:** Método de otimização não-linear sem restrições.
- **Convergência:** Rápida, especialmente para problemas de grande escala.

- **Eficiência:** Atualiza a matriz Hessiana inversa sem precisar recalculá-la diretamente, o que reduz a complexidade computacional.

O algoritmo BFGS utiliza a equação 3 para calcular o próximo passo (x_{k+1}) a cada iteração:

$$x_{k+1} = x_k - \alpha_k B_k^{-1} \nabla f(x_k) \quad (3)$$

A matriz B_k^{-1} é uma aproximação da matriz Hessiana inversa da função objetivo, calculada através da equação 4 e os termos s_k e y_k são calculados através das equações 5 e 6, respectivamente.

$$B_{k+1} = B_k + \frac{y_k y_k^T}{y_k^T s_k} - \frac{B_k s_k s_k^T B_k}{y_k^T B_k s_k} \quad (4)$$

$$s_k = x_{k+1} - x_k \quad (5)$$

$$y_k = \nabla f(x_{k+1}) - \nabla f(x_k) \quad (6)$$

O algoritmo tem aplicações em problemas de controle preditivo, otimização de trajetórias e ajustes de parâmetros em processos industriais complexos (SCIPY; NOCEDAL, 2006).

2.5.4. ALGORITMO SLSQP

O SLSQP (*Sequential Least Squares Quadratic Programming*) foi introduzido por Dieter Kraft em 1988 e é amplamente reconhecido por ser um método para resolver problemas de otimização não-linear com restrições. Ele combina técnicas de programação quadrática com métodos sequenciais para encontrar uma solução eficiente. O método transforma o problema em uma sequência de problemas quadráticos (SQP), em que a função objetivo é uma aproximação de segunda ordem do lagrangiano e as restrições são linearizações das restrições (SCIPY; KRAFT, 2006; MA, 2024). Características principais:

- **Tipo:** Método de otimização com restrições (igualdades e desigualdades).
- **Eficiência:** Adequado para problemas de médio porte em ambientes industriais.
- **Versatilidade:** Suporta restrições lineares e não-lineares.

Esse algoritmo é utilizado em otimização de processos, controle ótimo e problemas industriais onde há necessidade de respeitar limites físicos e operacionais (SCIPY; KRAFT, 2006; MA, 2024).

3. METODOLOGIA

3.1. PYTHON

A linguagem Python foi escolhida para o desenvolvimento do modelo de simulação devido à sua versatilidade, legibilidade e ampla gama de bibliotecas científicas. Python é uma linguagem de programação de alto nível, interpretada e amplamente utilizada em engenharia para modelagem matemática, análise de dados e otimização. Sua sintaxe intuitiva e comunidade ativa permitem o desenvolvimento rápido de soluções complexas, facilitando a implementação de cálculos termodinâmicos, otimizações e simulações computacionais (PYTHON).

Para o desenvolvimento deste projeto, foi utilizado o Google Colab, uma plataforma online que permite a execução de código Python em *notebooks* interativos. O Google Colab oferece uma infraestrutura baseada em nuvem, eliminando a necessidade de configuração local e garantindo acesso a recursos computacionais avançados. Além disso, ele conta com diversas bibliotecas científicas nativamente instaladas, como NumPy e SciPy, o que facilita a implementação do modelo. Outra vantagem é a possibilidade de executar os trechos de código modularmente, permitindo testes e ajustes rápidos sem a necessidade de rodar todo o script do início.

3.1.1. SCIPY MINIMIZE

A SciPy (Scientific Python) é uma biblioteca de código aberto voltada para computação científica em Python. Ela fornece um conjunto de ferramentas matemáticas avançadas para otimização, álgebra linear, integração numérica, estatística e processamento de sinais. A SciPy é amplamente utilizada em aplicações de engenharia e ciência, pois permite a implementação eficiente de algoritmos numéricos, facilitando a resolução de problemas complexos, como a otimização de processos industriais (SCIPY).

Para determinar os melhores parâmetros dos controladores PI, foi utilizada a função minimize da biblioteca SciPy. Essa função resolve problemas de minimização de funções multivariáveis e permite a definição de restrições e limites para garantir

soluções factíveis. A minimize suporta diversos algoritmos de otimização, como Nelder-Mead, Powell, BFGS, L-BFGS-B e SLSQP. Neste projeto, foram utilizados os algoritmos BFGS (Broyden–Fletcher–Goldfarb–Shanno) e SLSQP (Sequential Least Squares Programming). O modelo foi configurado para minimizar os distúrbios operacionais e maximizar a potência gerada, respeitando os limites de operação dos turbogeradores e garantindo a estabilidade do sistema (SCIPY).

A implementação foi feita definindo uma função objetivo que representa a penalidade sobre o erro operacional e a potência de exportação desejada, aplicando restrições que asseguram o cumprimento das condições termodinâmicas e mecânicas do processo.

3.1.2. COOL PROP

A pressão do sistema e outras propriedades termodinâmicas do vapor de água, foram obtidas utilizando a biblioteca *CoolProp*, que é uma biblioteca termodinâmica de código aberto que fornece propriedades de fluidos puros e misturas baseadas em equações de estado e modelos de transporte. Neste trabalho, a equação de estado de Peng-Robinson foi implementada para descrever o comportamento do vapor de água no sistema (BELL, 2014).

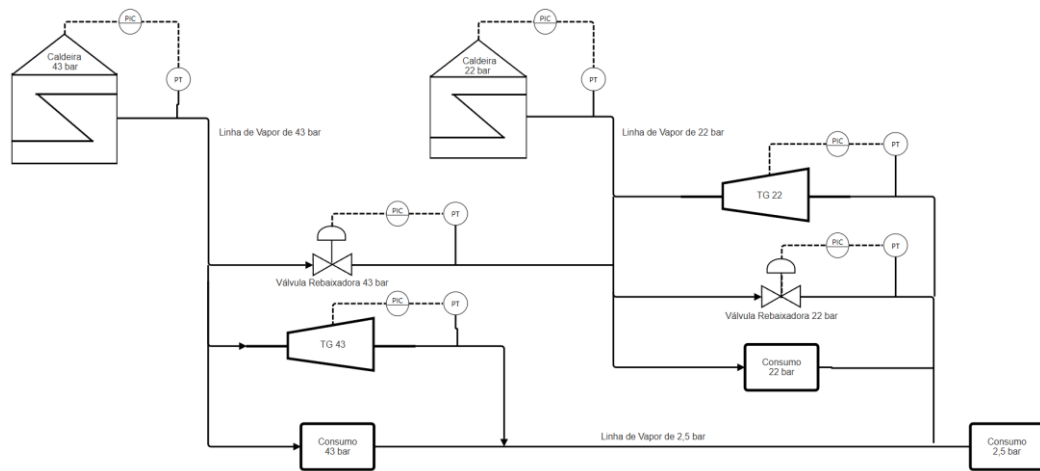
3.2. DESCRIÇÃO DO PROCESSO

A cogeração em estudo pode ser visualizada na figura 3 e opera com três linhas de vapor, sendo elas de alta (43 bar e 380 °C), média (22 bar e 340 °C) e baixa (2,5 bar e 150 °C) pressão. A linha de vapor de alta e de média são alimentadas por caldeiras de alta e de média pressão, respectivamente. Acionamentos mecânicos consomem vapor de alta e média pressão, rebaixando-o e alimentando a linha de baixa pressão. A linha de vapor de alta e de média contêm turbogeradores de contrapressão cada um consumindo vapor, rebaixando-o e alimentando a linha de baixa pressão. O processo conta com válvulas redutoras que rebaixam o vapor de alta para média pressão e vapor de média para baixa pressão. O processo consome vapor de baixa pressão principalmente para o aquecimento e evaporação do caldo e destilaria. As demandas por vapor de alta e de média pressão por acionamentos mecânicos, como também as demandas de vapor de baixa pressão para aquecimento, podem mudar ao longo do tempo, em função de diversas mudanças que ocorrem no processo.

A malha de controle terá disponível para manipular: Os alimentadores de bagaço das caldeiras, que controlam a alimentação de vapor das caldeiras nas linhas de vapor; O *set point* de potência dos turbogeradores, que controlam a potência gerada e a vazão de vapor consumida pelos turbogeradores; A abertura das válvulas reductoras, que controlam a vazão de vapor rebaixada por estas válvulas.

Cada turbogerador têm um limite mínimo e máximo de potência de trabalho a ser respeitada. A potência total gerada pelos turbogeradores subtraído da potência consumida pela planta, resulta na potência exportada pela planta industrial.

Figura 3 – Diagrama P&ID do processo de cogeração.



Fonte: Autoria própria.

3.3. ESTRATÉGIA DE CONTROLE

O controle da pressão nas três linhas de vapor, serão realizados por 6 controladores PI, que podem ser visualizados na figura 3 e estão dispostos da seguinte forma:

- A caldeira de vapor de 43 bar controlará a sua alimentação de vapor na linha, observando a pressão da linha de vapor de 43 bar.
- A caldeira de vapor de 22 bar controlará a sua alimentação de vapor na linha, observando a pressão da linha de vapor de 22 bar.
- Os turbogeradores de 43 bar e 22 bar controlarão a quantidade de vapor que rebaixam, observado a pressão da linha de vapor de 2,5 bar.
- A válvula rebaixadora de vapor de 43 bar para 22 bar controlará a quantidade de vapor que rebaixa, observando a pressão na linha de vapor de 22 bar.

- A válvula rebaixadora de vapor de 22 bar para 2,5 bar controlará a quantidade de vapor que rebaixa, observando a pressão na linha de vapor de 2,5 bar.

Para que cada controlador responda de forma otimizada aos distúrbios nas pressões das linhas de vapor, assim como os controladores os efeitos uns dos outros e atuem de forma a otimizar a exportação de energia elétrica, será aplicado um algoritmo de otimização dos parâmetros K_p e K_i de cada controlador, buscando minimizar uma função penalidade que observa a estabilidade da pressão nas linhas de vapor e a potência elétrica de exportação, em um determinado período futuro simulado.

3.4. MODELAGEM MATEMÁTICA DO PROCESSO

O controlador PI foi construído conforme a equação 7, o parâmetro de ajuste da parte proporcional é dado por K_p e da parte integral é dado por K_i . O controlador P foi construído a partir da equação 7, mas com o parâmetro K_i igual a 0, desta forma a parte integral da equação é desconsiderada.

O termo que subtrai a PV do SP, tem como valor resultante a distância da variável controlada ao alvo e aponta na direção contrária ao erro, de forma que se a variável controlada é diretamente proporcional à variável manipulada, um valor de K_p positivo irá fazer com que o controlador atue no sentido correto para corrigir o erro na variável controlada, assim, se a variável controlada for inversamente proporcional à variável manipulada, um valor de K_p negativo irá fazer com que o controlador atue no sentido correto para corrigir o erro na variável controlada. A parte integral da equação 2, se trata de uma integração do produto do erro com o parâmetro K_i , em todo o tempo de execução do controle.

$$PI(PV, SP) = K_p(SP - PV) + \int K_i(SP - PV)dt \quad (7)$$

O controlador PI tem como sinal de saída para as caldeiras um valor percentual de velocidade de alimentação de combustível na fornalha (MV_{calda}), limitado de 20 a 80% (Equação 8).

$$MV_{calda} = PI(PV - SP), \quad 20\% < MV_{calda} < 80\% \quad (8)$$

O controlador PI tem como sinal de saída para as válvulas rebaixadoras de vapor um valor percentual de abertura da válvula (MV_{Reb}), limitado de 0 a 100% (Equação 9).

$$MV_{Reb} = PI(PV - SP), \quad 0\% < MV_{Reb} < 100\% \quad (9)$$

O controlador PI tem como sinal de saída para os turbogeradores um valor alvo de potência gerada (Pot_{TG}), limitada por uma potência mínima de operação, em que o consumo específico de vapor do turbogerador se torna o máximo aceitável e uma potência máxima, definida pela capacidade do turbogerador em função da sua construção e estado de conservação (Equação 10).

$$Pot_{TG} = PI(PV - SP), \quad minima < Pot_{TG} < máxima \quad (10)$$

A variável manipulada das caldeiras que controlam a velocidade de alimentação de combustível na fornalha, definem, em função da capacidade máxima da caldeira (Cap_{cald}) dada em função da construção da caldeira, estado de conservação do equipamento e condição da combustão do combustível alimentado (CASTRO, 2020), a vazão de vapor que a caldeira (m_{cald}) está produzindo e alimentando a sua respectiva linha de vapor (Equação 11).

$$m_{cald} = \frac{MV_{cald}}{100} Cap_{cald} \quad (11)$$

A variável manipulada das válvulas rebaixadoras de vapor que controlam a abertura da válvula, definem, em função da capacidade máxima da válvula rebaixadoras (Cap_{Reb}) dada em função da construção da válvula e pressão nas linhas de vapor na entrada e saída da válvula, a vazão de vapor que a válvula está rebaixando (m_{Reb}) e alimentando a sua respectiva linha de vapor (Equação 12)

$$m_{Reb} = \frac{MV_{Reb}}{100} Cap_{Reb} \quad (12)$$

O alvo de potência dos turbogeradores, definem, em função do consumo específico do turbogerador (CE_{TG}), que é dado pela construção do turbogerador, parâmetros termodinâmicos do vapor na entrada e saída do turbogerador e carga no turbogerador, a vazão de vapor que o turbogerador está rebaixando (m_{TG}), gerando energia elétrica e alimentando a sua respectiva linha de vapor (Equação 13).

$$m_{TG} = Pot_{TG} CE_{TG} \quad (13)$$

A equação diferencial da variação de massa de vapor na linha de vapor de 43 bar, é dada pela equação 14, resultado do balanço de massa do sistema, em que a caldeira de 43 bar alimenta a linha e há um consumo de vapor de 43 bar da linha pela planta, pelo turbogerador de 43 bar e pela válvula rebaixadora de 43 bar.

$$\frac{dM_{43}}{dt} = m_{Cald43} - m_{Cons43} - m_{TG43} - m_{Reb43} \quad (14)$$

A equação diferencial da variação de massa de vapor na linha de vapor de 22 bar, é dada pela equação 15, resultado do balanço de massa do sistema, em que a caldeira de 22 bar e válvula rebaixadora de vapor de 43 bar alimentam a linha e há um consumo de vapor de 22 bar da linha pela planta, pelo turbogerador de 22 bar e pela válvula rebaixadora de 22 bar.

$$\frac{dM_{22}}{dt} = m_{Cald22} + m_{Reb43} - m_{Cons22} - m_{TG22} - m_{Reb22} \quad (15)$$

A equação diferencial da variação de massa de vapor na linha de vapor de 2,5 bar, é dada pela equação 16, resultado do balanço de massa do sistema, em que os consumidores da planta de 43 bar e 22 bar, turbogeradores de 43 bar e 22 bar e válvula rebaixadora de vapor de 22 bar alimentam a linha e há um consumo de vapor de 22 bar pela planta.

$$\frac{dM_{2,5}}{dt} = m_{Cons43} + m_{Cons22} + m_{TG43} + m_{TG22} + m_{Reb22} - m_{Cons2,5} \quad (16)$$

As equações diferenciais serão integradas no tempo decorrido ao longo da simulação (Equação 17), totalizando a massa de vapor contida em cada linha (M) a cada momento do processo. A massa de vapor contida na linha foi restrita a valores maiores ou iguais a zero, para impedir a ocorrência de massa negativa no sistema.

$$M = \int \frac{dM}{dt} dt \quad (17)$$

A pressão em cada linha de vapor (p) será calculada através da equação 18, que utiliza a equação de estado de Peng-Robinson com parâmetros da água para realizar a estimativa do vapor de água superaquecido, a partir de duas variáveis termodinâmicas, a temperatura do vapor na linha (T) e a densidade do vapor na linha (d) que é calculada a partir da equação 19 em função da massa contida (M) e o volume (V) da linha de vapor.

$$p = PengRobinson(T, d) \quad (18)$$

$$d = \frac{M}{V} \quad (19)$$

A potência elétrica gerada na cogeração (Pot_{Gerada}), calculada pela equação 20, é o total da potência gerada no turbogerador de 43 bar (Pot_{TG43}) e no turbogerador de 22 bar (Pot_{TG22}).

$$Pot_{Gerada} = Pot_{TG43} + Pot_{TG22} \quad (20)$$

A potência elétrica excedente, exportada para a rede elétrica (Pot_{Export}), calculada pela equação 21, é resultado da subtração da potência consumida pela planta industrial (Pot_{planta}) da potência elétrica gerada total (Pot_{Gerada}).

$$Pot_{Export} = Pot_{Gerada} - Pot_{planta} \quad (21)$$

3.5. FUNÇÃO OBJETIVO

O algoritmo de otimização aplicado, descrito na estratégia de controle, minimiza uma função objetivo (equação 22) que deverá indicar o desempenho dos controladores em cada linha de vapor e a potência de energia elétrica exportada, em uma simulação sobre um horizonte de tempo futuro (H, equação 23).

$$\min f(X) \quad (22)$$

$$H = t_{n+1} - t_n \quad (23)$$

As variáveis manipuladas (X, equação 24) serão os ganhos proporcionais (Kp) e integrais (Ki) dos controladores das caldeiras, turbogeradores e válvulas rebaixadoras das linhas de vapor de 43 bar e 22 bar.

$$X = (Kp_{Cald43}, Kp_{TG43}, Kp_{Reb43}, Kp_{Cald22}, Kp_{TG22}, Kp_{Reb22}, \\ Ki_{Cald43}, Ki_{TG43}, Ki_{Reb43}, Ki_{Cald22}, Ki_{TG22}, Ki_{Reb22}) \quad (24)$$

A forma escolhida para estimar o desempenho da malha de controle para gerar uma pontuação a ser minimizada, foi a penalidade (P), que é um valor positivo, em que o valor 0 indica o melhor estado e quanto maior for o seu valor, indica uma piora no desempenho. A função objetivo (f, equação 25) totaliza a penalidade do processo em um tempo simulado no futuro

$$f(X) = \int_{t_n}^{t_{n+1}} P(X) dt \quad (25)$$

A função penalidade (P, equação 26) soma as penalidades individuais de cada parâmetro de controle do processo, ponderadas por pesos α .

$$P(X) = \alpha_{43} g(PV_{43}, SP_{43}) + \alpha_{22} g(PV_{22}, SP_{22}) + \alpha_{2,5} g(PV_{2,5}, SP_{2,5}) + \alpha_{Export} h(PV_{Export}, SP_{Export}) \quad (26)$$

A função que estima a penalidade aplicada à pressão de cada linha de vapor (g, equação 27) é uma equação quadrática normalizada pelo *set point*.

$$g(PV, SP) = \left(\frac{PV - SP}{SP} \right)^2 \quad (27)$$

A função que estima a penalidade aplicada à potência de energia elétrica exportada pelo processo (h) é uma equação quadrática (Equação 28) igual a anterior, ou linear (Equação 29).

$$h(PV, SP) = \left(\frac{PV - SP}{SP} \right)^2 \quad (28)$$

$$h(PV, SP) = \left| \frac{PV - SP}{SP} \right| \quad (29)$$

Os primeiros testes serão realizados com todos os pesos α iguais a 1 e a função h igual à função g. E conforme necessário ao longo dos testes, estes parâmetros serão ajustados.

3.6. ESTUDO DE CASO

Na primeira etapa do estudo, será testado o desempenho da estratégia de controle usando apenas controladores P e PI, para identificar as vantagens e desvantagens de cada um e definir o melhor controlador a se seguir no estudo. Nesta etapa as simulações serão realizadas para quatro diferentes horizontes de tempo simulado avaliados, sendo eles 5, 10, 20 e 40 segundos no futuro. Nesta etapa a simulação terá a duração de 100 segundos e ocorrerá apenas uma alteração no processo, o *set point* da pressão de vapor de 2,5 bar será alterado para 2,55 bar a partir dos 10 segundos de simulação.

Na segunda etapa, o controlador escolhido na etapa anterior será testado em cinco diferentes horizontes de tempo de integração, sendo eles 5, 10, 20, 40 e 80 segundos,

em um cenário da planta com mais mudanças, para escolher o horizonte com melhor desempenho. Caso, os melhores horizontes tenham resultados semelhantes, estes serão testados em um novo cenário com a duração da simulação de 120 segundos, ocorrendo mudanças de *set point* das pressões nas linhas de vapor e distúrbios na vazão de vapor consumida pelo processo nas três linhas de vapor. Será selecionado o horizonte de tempo com o melhor desempenho.

Na terceira etapa, serão testados os algoritmos de otimização dos parâmetros dos controladores, sendo eles BFGS, SLSQP irrestrito, SLSQP restrito. Será selecionado o algoritmo de otimização com o melhor desempenho.

Na quarta etapa do estudo, serão testadas variações nas curvas de penalidades da potência de energia elétrica exportada. A configuração que manter baixo os desvios das pressões das linhas de vapor e apresentar a maior média da potência exportada, será selecionada.

A configuração padrão do controle utilizada para os testes foi a seguinte:

- Controle
 - Controladores: PI
 - Algoritmo de otimização: BFGS
 - Horizonte de avaliação: 10 segundos
 - Valores iniciais dos parâmetros K_p e K_i : 0
 - Restrição dos parâmetros K_p e K_i : Sem restrição
 - Peso entre as penalidades: 1
 - Função de penalidade para a exportação: Quadrática
- Linha de vapor de 43 bar:
 - Pressão: 43 bar
 - Set point de pressão: 43 bar
 - Temperatura: 380 °C
 - Volume: 150 m³
- Linha de vapor de 22 bar:
 - Pressão: 22 bar
 - Set point de pressão: 22 bar
 - Temperatura: 340 °C
 - Volume: 150 m³

- Linha de vapor de 2,5 bar:
 - Pressão: 2,5 bar
 - Set point de pressão: 2,5 bar
 - Temperatura: 180 °C
 - Volume: 150 m³
- Turbogenerador de 43 bar:
 - Alimentação: Vapor de 43 bar
 - Saída: Vapor de 2,5 bar
 - Potência inicial: 18,75 MW
 - Potência mínima: 5 MW
 - Potência máxima: 22 MW
 - Consumo específico: 8 ton/MWh
- Turbogenerador de 22 bar:
 - Alimentação: Vapor de 22 bar
 - Saída: Vapor de 2,5 bar
 - Potência inicial: 2,08 MW
 - Potência mínima: 1 MW
 - Potência máxima: 3 MW
 - Consumo específico: 12 ton/MWh

4. RESULTADOS


A simulação do processo com a estratégia de controle aplicada, foi desenvolvida com a linguagem de programação Python, na plataforma Google Colaboratory. Foram realizados testes em diferentes cenários, que aparecerão a seguir. Os gráficos foram gerados com a biblioteca Matplotlib.

4.1. COMPARAÇÃO ENTRE CONTROLES P E PI

Na primeira etapa, foram realizados testes do controle utilizando controladores P e PI, em quatro horizontes de tempo avaliados diferentes (40, 20, 10 e 5 segundos), para selecionar o controlador com o melhor desempenho. O cenário de teste escolhido inicia sem distúrbios no processo, a simulação dura 100 segundos e a partir de 10 segundos, o *set point* de pressão da linha de vapor de 2,5 bar é alterado para 2,55 bar.


As figuras 4, 5, 6 e 7 mostram os gráficos gerados da simulação com os controladores P e com os horizontes de avaliação de 40, 20, 10 e 5 segundos, respectivamente. O controle respondeu à alteração do set point da linha de vapor de 2,5 bar com um bom desempenho, no entanto, resultou em *offset* nas demais linhas de vapor, sendo mais acentuado conforme o horizonte de avaliação diminuía. Concluiu-se que o controle P teve um bom desempenho para responder rapidamente à mudança de *set point*, no entanto sozinho, resulta em *off set*.

Figura 4 – Simulação com controlador P e otimização por BFGS avaliando 40 segundos.




Fonte: Autoria própria.

Figura 5 – Simulação com controlador P e otimização por BFGS avaliando 20 segundos.




Fonte: Autoria própria.

Figura 6 – Simulação com controlador P e otimização por BFGS avaliando 10 segundos.



Fonte: Autoria própria.


Figura 7 – Simulação com controlador P e otimização por BFGS avaliando 5 segundos.



Fonte: Autoria própria.


As figuras 8, 9, 10 e 11 mostram os gráficos gerados da simulação com os controladores PI e com os horizontes de avaliação de 40, 20, 10 e 5 segundos, respectivamente. O controle respondeu rapidamente à alteração do *set point* da linha de vapor de 2,5 bar, semelhante ao controlador P, sem resultar em *off set* ou *hunting* que permanecem. No entanto, a pressão na linha de vapor de 2,5 bar resultou em um pequeno *overshoot* na mudança de *set point* em dois cenários, além de provocar nas demais linhas um período com *hunting* em baixa amplitude, estes efeitos foram minimizados com a redução do horizonte de avaliação. Conclui-se que o controlador PI demonstra os benefícios do controlador P e da ação integral, a rapidez do proporcional e correção de *offset* do integral, mas ainda levemente com as desvantagens destes, um pouco de *hunting* e *overshoot*.

Figura 8 – Simulação com controlador PI e otimização por BFGS avaliando 40 segundos.




Fonte: Autoria própria.

Figura 9 – Simulação com controlador PI e otimização por BFGS avaliando 20 segundos.




Fonte: Autoria própria.

Figura 10 – Simulação com controlador PI e otimização por BFGS avaliando 10 segundos.



Fonte: Autoria própria.

Figura 11 – Simulação com controlador PI e otimização por BFGS avaliando 5 segundos.



Fonte: Autoria própria.

Os dois tipos de controladores foram resumidos na tabela 1. A penalidade totalizada em cada simulação demonstrou que o controlador P é consistente nos resultados, independente do horizonte de avaliação, porém apresenta em média uma penalidade de 0,9422. Já o controlador PI apresentou duas simulações com as melhores penalidades e dois resultados intermediários próximos ao do controlador proporcional, apresentando em média uma penalidade de 0,9359, o que indica um desempenho superior ao controlador P.

Tabela 1 – Resultado das simulações comparando os controladores P e PI.

Figura	Controlador	Horizonte (s)	Penalidade
4	P	40	0,94183
5	P	20	0,94202
6	P	10	0,94253
7	P	5	0,94252
8	PI	40	0,92638
9	PI	20	0,94182
10	PI	10	0,93324
11	PI	5	0,94219

Fonte: Aatoria própria.

A partir da análise dos gráficos da simulação foi verificado que o controlador PI obteve os melhores desempenhos, além disso, com base na análise das penalidades, chegou-se que o controlador PI também indicou o melhor desempenho. Conclui-se nesta primeira etapa que o controlador PI foi superior ao P e, portanto, foi escolhido para continuar nos demais testes.

4.2. AVALIAÇÃO DO EFEITO DO HORIZONTE DE INTEGRAÇÃO


Na segunda etapa, foram realizados testes do controle utilizando o controlador PI, em cinco diferentes horizontes de tempo avaliado (80, 40, 20, 10 e 5 segundos), para selecionar os horizontes com o melhor desempenho. O cenário de teste escolhido inicia sem distúrbios no processo, a simulação dura 100 segundos, a partir de 10 segundos, o *set point* de pressão da linha de vapor de 2,5 bar é alterado para 2,55 bar, a partir de 40 segundos, o *set point* de pressão da linha de vapor de 22 bar é alterado para 22,3 bar, a partir de 70 segundos, o *set point* de pressão da linha de vapor de 43 bar é alterado para 43,5 bar e o *set point* de pressão da linha de vapor de 2,5 bar é alterado para 2,5 bar.

As figuras 12, 13, 14 e 15 mostram os gráficos gerados da simulação com os horizontes de avaliação de 80, 40, 20, 10 e 5 segundos, respectivamente. Foi observado que um menor tempo do horizonte avaliado, confere maior velocidade na resposta às mudanças de *set point*, porém também causa mais *overshot*, sucedido de um período oscilatório que não permanece. Do outro lado, um horizonte maior considera mais distúrbios por otimização dos parâmetros sendo mais lento por trabalhar com parâmetros mais gerais, enquanto horizontes menores oferecem maior frequência de ajuste dos controladores aos cenários e melhor desempenho em

cenários com mais mudanças de *set point* e distúrbios do processo. Este comportamento indica que o tempo de avaliação do horizonte ótimo pode variar em função da frequência e duração dos distúrbios característicos do processo a ser controlado.


Na simulação da figura 12, foi observado que um horizonte de tempo muito grande prejudicou a flexibilidade proposta por aplicar o otimizador na estratégia de controle e apresentou um baixo desempenho. A simulação da figura 16 apresentou uma alta reatividade às mudanças no processo, com *overshot* significativo, gerando um período oscilatório, também apresentando um desempenho inferior. As demais simulações das figuras 13, 14 e 15 apresentaram um resultado mais satisfatório, com um destaque para as simulações das figuras 13 e 15, que permaneceram por um tempo mais significativo com a potência exportada em valores superiores às demais.

Figura 12 – Simulação com controlador PI e otimização por BFGS avaliando 80 segundos.




Fonte: Autoria própria.

Figura 13 – Simulação com controlador PI e otimização por BFGS avaliando 40 segundos.




Fonte: Autoria própria.

Figura 14 – Simulação com controlador PI e otimização por BFGS avaliando 20 segundos.




Fonte: Autoria própria.

Figura 15 – Simulação com controlador PI e otimização por BFGS avaliando 10 segundos.



Fonte: Autoria própria.

Figura 16 – Simulação com controlador PI e otimização por BFGS avaliando 5 segundos.



Fonte: Autoria própria.

As cinco simulações foram resumidas na tabela 2. As maiores penalidades foram obtidos com o maior e o menor horizonte de tempo avaliado, indicando que tiveram um baixo desempenho, provavelmente o maior tempo é muito grande para a frequência dos distúrbios deste processo, fazendo com que poucas otimizações fossem realizadas em relação ao número de distúrbios que surgiram no período, o inverso deve ter ocorrido com o menor tempo, sendo pequeno o suficiente, para que o algoritmo de otimização não consiga observar de forma efetiva, os efeitos causados no processo, para cada combinação dos parâmetros dos controladores testados, prejudicando o potencial de otimização frente aos distúrbios da planta. As demais

simulações apresentaram um bom desempenho, sendo as duas menores penalidades as simulações com um horizonte de 40 e 10 segundos.

Tabela 2 – Resultado das simulações comparando cinco horizontes de tempo.


Figura	Controle	Horizonte (s)	Penalidade
12	PI	80	0,94836
13	PI	40	0,92815
14	PI	20	0,93955
15	PI	10	0,93225
16	PI	5	0,94520

Fonte: A autoria própria.

A partir da análise dos gráficos das simulações chegou-se que os horizontes de 40, 20 e 10 segundos apresentam um bom desempenho de controle das pressões nas linhas de vapor, com destaque aos horizontes de 40 e 10 segundos que apresentaram maiores potências de exportação, além disso, com base na análise das penalidades, chegou-se que os horizontes de 40 e 10 segundos indicou terem os melhores desempenhos. Conclui-se nesta segunda etapa que os horizontes de tempo avaliado de 40 e 10 segundos demonstraram os melhores desempenho, com resultados semelhantes, portanto, será realizado uma segunda parte dos testes com estes dois horizontes.

Na segunda parte da etapa 2, foram realizados testes do controle utilizando o controlador PI, em dois diferentes horizontes de tempo avaliado (40 e 10 segundos), para selecionar o horizonte com o melhor desempenho. O cenário de teste escolhido, além de mudança de *set point*, contém mudanças nos consumidores de vapor do processo (Figura 17), é iniciado sem distúrbios, a simulação dura 120 segundos, entre 10 e 20 segundos de simulação o consumo de vapor de 43 bar pelo processo reduz em 1 ton/h por segundo, entre 40 e 50 segundos de simulação o consumo de vapor de 2,5 bar pelo processo aumenta em 0,5 ton/h por segundo, entre 50 e 55 segundos de simulação o consumo de vapor de 22 bar pelo processo reduz em 1 ton/h por segundo, entre 50 e 60 segundos de simulação o consumo de vapor de 2,5 bar pelo processo aumenta em 1 ton/h por segundo, entre 60 e 80 segundos de simulação o consumo de vapor de 43 bar aumenta em 0,5 ton/h por segundo, entre 75 e 85 segundos de simulação o set point de pressão do vapor de 2,5 bar aumenta para 2,6 bar e na sequência retorna para 2,5 bar.


Figura 17 – Cenário de simulação com distúrbios nos consumidores de vapor do processo.



Fonte: Autoria própria.


As figuras 18 e 19 mostram os gráficos da simulação neste cenário, para um horizonte de tempo de 40 e 10 segundos, respectivamente. O horizonte de 40 segundos obteve melhores resultados comparando até 80 segundos, enquanto no horizonte de 10 segundos ocorreu *overshot*. Analisando a partir de 80 segundos, o horizonte de 40 segundos ficou instável, variando bruscamente a pressão do sistema, enquanto o horizonte de 10 segundos ficou instável por um período menor e com menor amplitude e a partir de 100 segundos da simulação retornou à estabilidade.

Figura 18 – Simulação com controlador PI e otimização por BFGS avaliando 40 segundos.



Fonte: Autoria própria.

Figura 19 – Simulação com controlador PI e otimização por BFGS avaliando 10 segundos.



Fonte: Autoria própria.


Conclui-se que os controladores estão bastante reativos, provavelmente ocasionado por valores elevados dos parâmetros K_p e K_i dos controladores, causando

instabilidade ao sistema, não permitindo cumprir com o objetivo desta etapa de selecionar o horizonte com o melhor desempenho. Portanto, houve a necessidade de estudar o algoritmo de otimização que define os parâmetros para os controladores, para minimizar o comportamento de instabilidade observado neste segundo teste.

4.3. COMPARAÇÃO DOS ALGORITMOS DE OTIMIZAÇÃO

Na terceira etapa, foram realizados testes do controle utilizando o controlador PI, com o horizonte de tempo de avaliação para 10 segundos e um teste final com 40 segundos, para selecionar o algoritmo de otimização com o melhor desempenho e comparar o desempenho entre estes dois horizontes de tempo. O cenário de teste escolhido contempla 100 segundos de simulação e apenas um distúrbio temporário aumentando o consumo de vapor de 2,5 bar pelo processo e depois retornando ao cenário inicial, para avaliar a reação dos controles a distúrbios significativos em uma variável e analisar a resposta do controle em um cenário que os turbogeradores precisam do auxílio das válvulas rebaixadoras para suprir a demanda de vapor do processo. Entre 30 e 40 segundos de simulação o consumo de vapor de 2,5 bar pelo processo aumenta em 2 ton/h por segundo e entre 60 e 70 segundos, reduz em 2 ton/h por segundo, podendo ser visualizado nos gráficos da figura 20.


Figura 20 – Cenário de simulação com distúrbio no consumidor de vapor de 2,5 bar do processo.



Fonte: Autoria própria.


A figura 21 mostra os gráficos da simulação com o horizonte de 10 segundos e usando o algoritmo de otimização BFGS, o controle demonstrou uma boa estabilidade das pressões nas linhas de vapor, no entanto, oscilou bruscamente a pressão na linha de vapor de 2,5 bar. Analisando os gráficos dos parâmetros K_p e K_i do controle no tempo, na figura 22, foi observado que os parâmetros assumem valores muito elevados, o que é possível, devido a impossibilidade do algoritmo de otimização utilizado restringir o intervalo das soluções, causando a alta reatividade observada.

Figura 21 - Simulação com controlador PI e otimização por BFGS sem restrição avaliando 10 segundos.



Fonte: Autoria própria.


Figura 22 - Simulação com controlador PI e otimização por BFGS sem restrição avaliando 10 segundos.



Fonte: Autoria própria.


A figura 23 mostra os gráficos da simulação com o horizonte de 10 segundos e usando o algoritmo de otimização SLSQP sem restrição, foram observados os mesmos problemas da simulação anterior, quanto a alta reatividade do controle e observado elevados valores dos parâmetros dos controladores na figura 24.

Figura 23 - Simulação com controlador PI e otimização por SLSQP sem restrição avaliando 10 segundos.



Fonte: Autoria própria.


Figura 24 - Simulação com controlador PI e otimização por SLSQP sem restrição avaliando 10 segundos.



Fonte: Autoria própria.


A figura 25 mostra os gráficos da simulação com o horizonte de 10 segundos e usando o algoritmo de otimização SLSQP com restrições para o conjunto de solução do problema de otimização, o parâmetro K_p dos controladores foi restrito a valores de -10 a 10 e o parâmetro K_i foi restrito a valores de -5 a 5, desta forma o algoritmo de otimização se limita a explorar valores factíveis para os parâmetros dos controladores PI, sendo o intervalo do K_i a metade do intervalo do parâmetro K_p , para minimizar a instabilidade causada pela inércia da ação do controle integral. A figura 26 mostra os gráficos dos parâmetros K_p e K_i dos controladores no tempo, os quais não ultrapassaram os limites estabelecidos e foi verificado que apenas os parâmetros da parte integral chegaram ao valor máximo permitido, indicando que não houve prejuízo à ação proporcional e que o efeito da ação proporcional foi limitado, de forma a minimizar seus efeitos negativos. Com esta melhoria, o gráfico das pressões não apresentou instabilidades causadas por uma elevada sensibilidade do controle aos distúrbios.

Figura 25 - Simulação com controlador PI e otimização por SLSQP com restrição avaliando 10 segundos.



Fonte: Autoria própria.

Figura 26 - Simulação com controlador PI e otimização por SLSQP com restrição avaliando 10 segundos.




Fonte: Autoria própria.

A figura 27 mostra os gráficos da simulação com o horizonte de 40 segundos e usando o algoritmo de otimização SLSQP com as mesmas restrições para o conjunto de solução do problema de otimização da simulação anterior. Foi observado uma melhora no desempenho do controle das pressões das linhas e não ocorreram instabilidades causadas por elevada sensibilidade aos distúrbios, a figura 28 mostra que os valores dos parâmetros Kp e Ki dos controladores ficaram restritos aos intervalos definidos.


Dentre as simulações desta etapa, esta configuração demonstrou o melhor desempenho. O aumento do horizonte de avaliação provavelmente permitiu o algoritmo de otimização a considerar mais profundamente os efeitos dos parâmetros em cada otimização, permitindo encontrar soluções que se adaptem à correção do distúrbio como um todo e não considerando apenas um trecho pequeno da simulação ao usar um horizonte menor, o qual pode beneficiar em diminuir a penalidade no trecho atual, mas prejudicar as ações futuras do controle. Portanto, fica evidente a necessidade de as ações de controle considerarem o momento atual e futuro nas tomadas de decisão.

Figura 27 - Simulação com controlador PI e otimização por SLSQP com restrição avaliando 40 segundos.



Fonte: Autoria própria.

Figura 28 - Simulação com controlador PI e otimização por SLSQP com restrição avaliando 40 segundos.



Fonte: Autoria própria.

As quatro simulações foram resumidas da tabela 3, a qual também apresenta a penalidade total, a potência exportada média e os desvios padrões das pressões em cada linha de vapor do processo na simulação. As simulações com o algoritmo SLSQP com restrição e o horizonte de integração de 40 segundos, apresentou uma das menores penalidades, uma das maiores potências de exportação médias e menores desvios padrões na pressão das linhas de vapor. A performance do algoritmo BFGS em relação a penalidade e exportação foram superiores aos do SLSQP, no entanto, os desvios padrões foram quase equivalentes ao SLSQP com restrição.

Tabela 3 – Resultados da simulação comparando os algoritmos de otimização.

Figuras	Horizonte (s)	Algoritmo	Penalidade	Exportação Média (MW)	Desvio Padrão (Bar)		
					43 bar	22 bar	2,5 bar
21 e 22	10	BFGS	0,91143	21,788	0,0615	0,0453	0,0103
23 e 24	10	SLSQP sem restrição	0,93017	21,480	0,0664	0,0854	0,0158
25 e 26	10	SLSQP com restrição	0,93139	21,505	0,1569	0,1453	0,0108
27 e 28	40	SLSQP com restrição	0,92309	21,519	0,0542	0,0849	0,0107

Fonte: Autoria própria.

A tabela 3 apresenta o desvio padrão da saída de cada controlador PI por algoritmo de otimização testado, para simulações com o horizonte de integração de 10 segundos. Foi observado que o algoritmo SLSQP sem restrição demonstrou os menores desvios padrões no controlador da caldeira de 22 bar e na válvula rebaixadora de vapor de 43 bar, enquanto o algoritmo SLSQP com restrição apresentou os menores desvios padrões nos demais controladores. Além disso, observando os gráficos das figuras 21 e 23 é perceptível a ocorrência de variações bruscas na pressão da linha de vapor de 2,5 bar, o que na prática, pode ser prejudicial ao sistema de tubulação, que associado aos maiores desvios padrões dos controladores nestas linhas, indicam um risco de ocorrer golpes de aríete na tubulação, não sendo viáveis, o que não é observado nos gráficos da figura 25.

Tabela 4 - Desvio padrão dos controladores por algoritmo de otimização.

Controlador	Desvio padrão do controlador		
	BFGS	SLSQP sem restrição	SLSQP com restrição
Caldeira 43	4,26	3,23	2,20
Caldeira 22	5,73	2,27	5,42
Válvula 43	0,91	0,00	2,56
Válvula 22	1,10	1,06	0,05
Turbogerador 43	1,03	1,26	0,48
Turbogerador 22	0,57	0,81	0,42

Fonte: Autoria própria.


Conclui-se a partir da análise dos gráficos, que os algoritmos de otimização sem restrição não foram adequados para este controle e com base nas tabelas 3 e 4, o algoritmo de otimização SLSQP com restrição e horizonte de 40 segundos apresentou os melhores desempenhos. Portanto, o algoritmo SLSQP com restrição e avaliando

um horizonte de 40 segundos é a configuração factível com o melhor desempenho, o qual demonstrou boa estabilidade e capacidade de corrigir os distúrbios do processo e mantendo a potência de exportação estável em cada diferente condição do processo.

4.4. AJUSTANDO A PENALIDADE DA EXPORTAÇÃO

Na quarta etapa, foram realizados testes do controle utilizando o controlador PI, com o horizonte de tempo de avaliação para 40 segundos, com a diferença na equação de penalidade da potência de exportação, podendo ser linear ou quadrática. O cenário de teste escolhido contempla 100 segundos de simulação e apenas um distúrbio temporário aumentando o consumo de vapor de 2,5 bar pelo processo e depois retornando ao cenário inicial. Entre 30 e 40 segundos de simulação o consumo de vapor de 2,5 bar pelo processo aumenta em 2 ton/h por segundo e entre 60 e 70 segundos, este diminui em 2 ton/h por segundo, podendo ser visualizado nos gráficos da figura 29.

Figura 29 – Cenário de simulação com distúrbio no consumidor de vapor de 2,5 bar do processo.




Fonte: Autoria própria.

A figura 30 e 31 são referentes à simulando com a função quadrática penalizando a exportação de energia. Foi observado que ocorre uma queda na pressão do vapor de 2,5 bar quando a demanda deste aumenta, no entanto os controles atuam consumindo vapor das demais linhas, o que causa um pequeno distúrbio nestas linhas de vapor. Neste cenário, o controle deu preferência a aumentar primeiro a vazão de vapor dos turbogeradores, privilegiando o aumento da potência de exportação do processo e na sequência a válvula rebaixadoras entra em ação e no retorno do distúrbio a válvula rebaixadoras tem sua abertura reduzida antes dos turbogeradores, favorecendo novamente o aumento da potência de exportação média. No entanto, o


turbogerador de 43 bar não atinge o seu valor máximo de geração de energia de 22 MW.

Figura 30 - Simulação com controlador PI e otimização por SLSQP com restrição avaliando 40 segundos e penalidade quadrática da exportação.



Fonte: Autoria própria.


Figura 31 - Simulação com controlador PI e otimização por SLSQP com restrição avaliando 40 segundos e penalidade quadrática da exportação.



Fonte: Autoria própria.


A figura 32 e 33 são referentes à simulando com a função linear penalizando a exportação de energia. Os mesmos comportamentos da simulação anterior foram observados também nesta configuração de controle.

Figura 32 - Simulação com controlador PI e otimização por SLSQP com restrição avaliando 40 segundos e penalidade linear da exportação.



Fonte: Autoria própria.

Figura 33 - Simulação com controlador PI e otimização por SLSQP com restrição avaliando 40 segundos e penalidade linear da exportação.



Fonte: Autoria própria.

A tabela 5 apresenta um resumo das duas simulações desta etapa, note que os resultados foram bastante semelhantes, apesar da diferença da função de penalidade, a primeira simulação teve uma média maior de exportação, no entanto também apresentou maiores desvios padrões na pressão das linhas de vapor, o que justifica a maior exportação.

Tabela 5 - Resultados da simulação comparando diferentes funções de penalidade.

Figuras	Horizonte (s)	Curva	Exportação Média (MW)	Desvio padrão (bar)		
				43 bar	22 bar	2,5 bar
30,31	40	Quadrática	21,596	0,0902	0,0721	0,0136
32,33	40	Linear	21,548	0,0795	0,0723	0,0126

Fonte: Autoria própria.

Conclui-se que esta estratégia de controle para este cenário, apresenta bons resultados, mas é limitada por sua forma de atuar indiretamente no processo, através dos controladores PID, que são ajustados em intervalos de tempo limitados e atuam de forma simples, observando apenas uma variável com magnitude proporcional a ela. Portanto, esta estratégia de controle provê ganhos operacionais, mas se esbarra em limitações inerentes dos controladores PI.

Portando, o método otimizado de sintonia utiliza controladores PI, para que a ação proporcional responda rapidamente às perturbações e minimize o efeito de *hunting*, enquanto a ação integral corrige possíveis *offsets* e ao realizar um bom ajuste dos parâmetros, o efeito de *overshot* em perturbações agressivas ao processo é minimizado. O horizonte de simulação foi definido em 40 segundos, para que o período avaliado seja amplo o suficiente para considerar de forma satisfatória os efeitos da sintonia dos controladores no processo e tenha uma frequência de sintonia otimizada para que os controladores respondam com melhor desempenho a novos

distúrbios no processo. O método SLSQP com restrição de -10 a 10 para a sintonia dos ganhos proporcionais e de -5 a 5 para os ganhos integrais, foi escolhida visando parâmetros limitados para que o controle atue com suavidade no processo, evitando prejuízos aos equipamentos, como exemplo a possibilidade de ocorrer golpe de aríete nas tubulações, além disso, para que permita estabelecer outras restrições se necessárias e para que encontre os melhores parâmetros de sintonia dos controladores. Além disso, utilizar funções quadráticas para penalizar a energia elétrica exportada proporcionou maior geração de energia, enquanto funções lineares levaram a desvio padrões menores na pressão das linhas de vapor, sendo duas opções viáveis, a serem testadas e escolhidas de acordo com a necessidade do processo.

5. CONCLUSÃO

Os resultados obtidos demonstraram que o método de sintonia periódica dos controladores, utilizando o algoritmo SLSQP com restrições nos ganhos proporcional e integral, proporcionou a melhor configuração para a estabilidade das pressões nas linhas de vapor e a maximização da exportação de energia elétrica. O horizonte de otimização de 40 segundos mostrou-se o mais eficiente, pois permitiu respostas rápidas às perturbações do sistema sem comprometer a robustez do controle. Além disso, a penalização quadrática da energia exportada resultou em maior exportação de energia, enquanto uma penalização linear favoreceu a estabilidade da pressão nas linhas de vapor, sendo duas opções a serem escolhidas de acordo com a necessidade do processo.

Esses resultados demonstram a viabilidade da aplicação de métodos de otimização para a sintonia dinâmica de controladores em sistemas de cogeração, especialmente em plantas sucroalcooleiras, onde há grande variabilidade nas demandas de vapor. A adoção dessa abordagem pode contribuir para a operação mais eficiente de unidades industriais, reduzindo perdas energéticas e melhorando a resposta do sistema a distúrbios operacionais.

Sua facilidade de implementação permite que seja adotado também em outras áreas da planta industrial e em outras indústrias além da sucroalcooleira, que envolvem controle de processos dinâmicos e multivariáveis. Além disso, sua integração em controladores lógicos programáveis (CLPs) poderia tornar essa metodologia uma tecnologia padrão na sintonia de controladores industriais, permitindo ajustes automáticos baseados em curvas de penalidade e garantindo maior eficiência operacional. No futuro, aprimoramentos nessa abordagem poderão incluir métodos mais avançados de otimização e *machine learning*, ampliando ainda mais sua aplicabilidade e impacto na indústria.

6. SUGESTÃO DE TRABALHOS FUTUROS

Durante as simulações, verificou-se que o desempenho dos controladores para corrigir um distúrbio, depende também do tempo em que a última otimização dos parâmetros ocorreu, desta forma, seria interessante realizar uma nova otimização dos parâmetros sempre que ocorrer uma alteração no *set point* ou o algoritmo detectar o

início de um novo distúrbio no processo, de forma que os parâmetros se ajustem ao novo cenário e a simulação contemple os efeitos dos novos distúrbios no processo.

As simulações realizadas neste estudo, não contemplaram a dinâmica de cada atuador e equipamento, os quais implicam nos processos reais em atrasos dos sinais dos controladores nos atuadores, atrasos na resposta das caldeiras às alterações nos alimentadores das fornalhas, um tempo até que as turbinas reajustem sua rotação para corresponder ao novo *set point* de potência gerada, entre outros efeitos.

É interessante aplicar a formulação IAPWS IF97 da biblioteca CoolProp para estimar a pressão do vapor de água em aplicações industriais.

REFERÊNCIAS BIBLIOGRÁFICAS

BORGNAKKE, C.; SONNTAG, R. E. Fundamentos da Termodinâmica. 8ª edição. São Paulo: Blucher, 2018.

SMITH, J. M. et al. Introdução à Termodinâmica da Engenharia Química. 8ª edição. São Paulo: LTC, 2019.

BOBROFF-MALU, A.; SÁNCHEZ, C. G. Avaliação termoeconômica da cogeração e da geração no setor sucroenergético. Revista Ciência e Tecnologia, v. 18, n. 33, p. 37-47, jul.-dez. 2015.

ALVES, M. Estudo de sistemas de cogeração em usinas de açúcar e álcool, com utilização do bagaço e palha da cana. 2011. 114 p. Dissertação (mestrado) - Universidade Estadual de Campinas, Faculdade de Engenharia Química, Campinas, SP.

FLACH, R. L. Desenvolvimento de sistema supervisor para automação e controle de sistema de cogeração de energia. 2024. 66 p. Monografia (graduação) - Universidade Federal de Santa Catarina, Campus Blumenau, 2024.

ANEEL. Bibliografia Temática: Cogeração de Energia Elétrica. Brasília, 2022.

OLIVEIRA, R. Simulação de um Ciclo de Rankine Utilizando o DWSIM. LinkedIn, 2024. Disponível em: <<https://www.linkedin.com/pulse/simula%C3%A7%C3%A3o-de-um-ciclo-rankine-utilizando-o-dwsim-rubens-oliveira-6axif/>>. Acesso em janeiro de 2025.

CASTRO, B.S. et al. Análise da influência da umidade do bagaço de cana-de-açúcar na cogeração de energia elétrica. In: ENCONTRO DE DESENVOLVIMENTO DE PROCESSOS AGROINDUSTRIAIS, Anais [...]. Uberlândia, 11-12 de dez. 2020.

BELL, I. H. et al. Pure and Pseudo-pure Fluid Thermophysical Property Evaluation and the Open-Source Thermophysical Property Library *CoolProp*. Ind. Eng. Chem. Res., v. 53, p. 2498–2508, janeiro de 2014.

PYTHON SOFTWARE FOUNDATION. Python: About. Disponível em: <<https://www.python.org/about/>>. Acesso em: fevereiro de 2025.

SCIPY. API Reference: Minimize. Disponível em: <<https://docs.scipy.org/doc/scipy/reference/generated/scipy.optimize.minimize.html>>. Acesso em janeiro de 2025.

NELDER, J. A.; MEAD, R. 1965. A Simplex Method for Function Minimization. The Computer Journal 7: 308-13.

MA, Y. et al. Improved SQP and SLSQP algorithms for feasible path-based process optimisation. Computers & Chemical Engineering, v. 188, setembro de 2024.

NOCEDAL, J.; WRIGHT, S. J. 2006. Numerical Optimization. Springer New York.

KRAFT, D. A software package for sequential quadratic programming. 1988. Tech. Rep. DFVLR-FB 88-28, DLR German Aerospace Center – Institute for Flight Mechanics, Koln, Germany.

JUNEJA, P. K. et al. A Review on Control System Applications in Industrial Processes. IOP Conference Series: Materials Science and Engineering, v. 1022, outubro de 2020.

BEQUETTE, B. W. Process Control: Modeling, Design and Simulation. 2ª edição, Pearson, julho de 2023.

ANG, K. H.; CHONG, G.; LI, Y. PID control system analysis, design, and technology. IEEE Transactions on Control Systems Technology. v 13, p. 559–576, julho de 2005.

HUGOT, E. Manual da Engenharia Açucareira. v. 1, São Paulo:Mestre Jou, 1969.

WOJSZNIS, W. K.; BLEVINS, T. Evolving PID tuning rules: A brief history, starting with the earliest PID controllers to the most recent developments. There is more continuity than you might expect. Control Engineering, março de 2013. Disponível em: <https://www.controleng.com/evolving-pid-tuning-rules/>. Acesso em fevereiro de 2025.

SOUSA, S. S. Estimando parâmetros de interação binária para a equação de Peng-Robinson via otimização multiobjetivo: um estudo com a regra clássica de mistura de Van Der Waals. 2022. 148 f. Tese (Doutorado em Modelagem Computacional) - Instituto Politécnico, Universidade do Estado do Rio de Janeiro, Nova Friburgo, 2022.