

UNIVERSIDADE FEDERAL DA PARAÍBA
CENTRO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA QUÍMICA

JOSE CARLOS DINIZ FILHO

**INTEGRAÇÃO DE CONTROLADORES PREDITIVOS DE MODELOS
ECONÔMICOS E OTIMIZAÇÃO EM TEMPO REAL APLICADOS
UMA PLANTA DE CAPTURA DE CARBONO**

JOÃO PESSOA-PB

2026

JOSE CARLOS DINIZ FILHO

**INTEGRAÇÃO DE CONTROLADORES PREDITIVOS DE MODELOS
ECONÔMICOS E OTIMIZAÇÃO EM TEMPO REAL APLICADOS UMA PLANTA
DE CAPTURA DE CARBONO**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Química do Centro de Tecnologia da Universidade Federal da Paraíba em cumprimento aos requisitos para obtenção do título de Mestre em Engenharia Química.

Orientador: Prof^o. Dr. Arioston Araújo de Moraes Júnior (UFPB)

Orientador: Prof^o. Dr. Rennio Felix de Sena (UFPB)

Coorientador: Prof^o. Dr. Márcio André Fernandes Martins (UFBA)

JOÃO PESSOA-PB

2026

**Catálogo na publicação
Seção de Catalogação e Classificação**

D585i Diniz Filho, Jose Carlos.

Integração de controladores preditivos de modelos econômicos e otimização em tempo real aplicados uma planta de captura de carbono / Jose Carlos Diniz Filho.
- João Pessoa, 2026.

76 f. : il.

Orientação: Arioston Araújo de Moraes Junior, Rennio Felix de Sena.

Coorientação: Márcio André Fernandes Martins.

Dissertação (Mestrado) - UFPB/CT.

1. Captura de CO₂. 2. Controle preditivo baseado em modelo. 3. Controle automático. 4. Controle de processos. 5. Otimização em tempo real. 6. Captura e armazenamento de carbono. 7. Monoetanolamina (MEA). 8. Sistemas multivariáveis. 9. Processos industriais. I. Moraes Junior, Arioston Araújo de. II. Sena, Rennio Felix de Sena. III. Martins, Márcio André Fernandes.

JOSE CARLOS DINIZ FILHO

**INTEGRAÇÃO DE CONTROLADORES PREDITIVOS DE MODELOS
ECONÔMICOS E OTIMIZAÇÃO EM TEMPO REAL APLICADOS UMA
PLANTA DE CAPTURA DE CARBONO**

Dissertação apresentada ao Programa de
Pós- Graduação em Engenharia Química
do Centro de Tecnologia da Universidade
Federal da Paraíba em cumprimento aos
requisitos para obtenção do título de
Mestre em Engenharia Química.

Aprovada em: 26/02/2026

BANCA EXAMINADORA

Documento assinado digitalmente
 **RENNIO FELIX DE SENA**
Data: 04/03/2026 13:59:27-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. Rennio Felix de Sena PPGEQ/CT/UFPB
(1º Orientador)

Documento assinado digitalmente
 **ARIOSTON ARAUJO DE MORAIS JUNIOR**
Data: 04/03/2026 11:53:17-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. Arioston Araújo de Moraes Junior (UFPB)
(2º Orientador)

Documento assinado digitalmente
 **MARCIO ANDRE FERNANDES MARTINS**
Data: 04/03/2026 14:52:30-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. Márcio André Fernandes Martins (UFBA)
(Coorientador)

Documento assinado digitalmente
 **RAQUEL MASSAD CAVALCANTE**
Data: 18/03/2026 16:38:10-0300
Verifique em <https://validar.iti.gov.br>

Profª. Dra. Raquel Massad Cavalcante (UFRJ)
(Examinadora externa)

Documento assinado digitalmente
 **RAONY MAIA FONTES**
Data: 06/03/2026 18:35:22-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. Raony Maia Fontes (UFBA)
(Examinador externo)

AGRADECIMENTOS

A realização deste trabalho representa a concretização de uma etapa importante da minha trajetória acadêmica e profissional, a qual não teria sido possível sem o apoio, a colaboração e o incentivo de diversas pessoas.

Agradeço, primeiramente, à minha família, que sempre esteve ao meu lado, oferecendo apoio incondicional, compreensão e incentivo em todos os momentos. Em especial, agradeço à minha esposa, pelo companheirismo, paciência e apoio constante ao longo dessa jornada, mesmo diante dos desafios e das renúncias exigidas pelo percurso acadêmico. À minha filha, fonte diária de motivação e inspiração, deixo meu agradecimento mais sincero, por me lembrar, todos os dias, do verdadeiro significado de persistir e evoluir.

Aos meus amigos, agradeço pela amizade, pelas conversas, pelo incentivo e pelo apoio moral, que tornaram essa caminhada mais leve e equilibrada, mesmo nos momentos de maior exigência.

Agradeço de forma especial aos meus orientadores, Prof. Dr. Arioston Araújo de Moraes Júnior, pela orientação técnica, disponibilidade, confiança e valiosas contribuições ao longo do desenvolvimento deste trabalho. A experiência, o conhecimento compartilhado e as discussões realizadas foram fundamentais para o amadurecimento científico deste estudo. Estendo também meu agradecimento ao Prof. Dr. Márcio André Fernandes Martins, pela coorientação, contribuições técnicas e apoio ao longo do desenvolvimento da pesquisa.

Por fim, agradeço à Universidade Federal da Paraíba, ao Programa de Pós-Graduação em Engenharia Química e a todos os professores e colaboradores que, direta ou indiretamente, contribuíram para a minha formação acadêmica e para a realização deste trabalho.

A todos, minha sincera gratidão.

RESUMO

A mitigação das emissões de dióxido de carbono (CO_2) provenientes da queima de combustíveis fósseis constitui um dos principais desafios tecnológicos e ambientais da atualidade. Nesse contexto, os sistemas de Captura e Armazenamento de Carbono (Carbon Capture and Storage – CCS) têm sido amplamente investigados, com destaque para os processos de pós-combustão baseados na absorção química com aminas, em razão de sua maturidade tecnológica e da possibilidade de integração a plantas industriais existentes. Contudo, o elevado consumo energético e os custos operacionais associados ainda limitam sua aplicação em larga escala, o que torna necessária a adoção de estratégias avançadas de modelagem, controle e otimização. Neste trabalho, desenvolve-se, implementa-se e avalia-se o desempenho de uma arquitetura integrada de controle preditivo baseado em modelo (Model Predictive Control – MPC) com objetivos econômicos e otimização em tempo real (Real-Time Optimization – RTO) aplicada a uma planta de captura de CO_2 por absorção química com monoetanolamina (MEA), simulada de forma rigorosa no Aspen Plus Dynamics®. Inicialmente, realizou-se a simulação dinâmica da planta, seguida da aplicação de sinais de excitação do tipo sequência binária pseudoaleatória (PRBS) para a obtenção de dados e identificação de modelos lineares multivariáveis do processo. Com base nesses dados, foram desenvolvidos modelos orientados à predição da saída (Output-Prediction Oriented Models – OPOM) e implementados controladores CLMPC e IHMPCFF, os quais atuam no rastreamento dinâmico dos alvos econômicos definidos pela camada de RTO. Adicionalmente, foi incorporado um filtro de Kalman para a estimação de estados não mensuráveis, proporcionando maior precisão preditiva e eliminando erros de regime permanente (offset). Os controladores MPC foram então integrados a uma camada superior de otimização econômica baseada em modelo em regime estacionário (RTO), responsável por recalcular periodicamente os pontos ótimos de operação, considerando custos energéticos, preço do CO_2 , consumo de solvente e penalidades ambientais. Os resultados demonstram que a integração RTO–MPC proporciona ganhos significativos em eficiência energética, maior estabilidade dinâmica e redução dos custos operacionais frente a variações de carga e composição do gás de combustão. Assim, conclui-se que a integração entre controle preditivo e otimização econômica constitui uma abordagem promissora para a operação sustentável e economicamente viável de plantas industriais de captura de CO_2 .

Palavras-chave: Captura de CO_2 ; Controle preditivo; Otimização em tempo real; Aspen Dynamics; Engenharia de controle.

ABSTRACT

The mitigation of carbon dioxide (CO₂) emissions resulting from the combustion of fossil fuels represents one of the major technological and environmental challenges of modern society. In this context, Carbon Capture and Storage (CCS) systems have been extensively investigated, particularly post-combustion processes based on chemical absorption with amines, due to their technological maturity and potential for integration into existing industrial plants. However, the high energy consumption and operational costs associated with these systems still limit their large-scale deployment, highlighting the need for advanced modeling, control, and optimization strategies. In this study, an integrated architecture combining Model Predictive Control (MPC) with economic objectives and Real-Time Optimization (RTO) is developed, implemented, and evaluated for a post-combustion CO₂ capture plant based on chemical absorption with monoethanolamine (MEA), rigorously simulated in Aspen Plus Dynamics®. Initially, dynamic simulation of the plant was performed, followed by the application of pseudo-random binary sequence (PRBS) excitation signals to generate data for the identification of linear multivariable process models. Based on these data, output-prediction oriented models (OPOM) were developed, and CLMPC and IHMPCFF controllers were implemented to dynamically track the economic targets defined by the RTO layer. In addition, a Kalman filter was incorporated for the estimation of non-measurable states, providing improved predictive accuracy and eliminating steady-state offset. The MPC controllers were subsequently integrated with a higher-level steady-state model-based economic optimization layer (RTO), responsible for periodically recalculating the optimal operating points while accounting for energy costs, CO₂ pricing, solvent consumption, and environmental penalties. The results demonstrate that the integrated RTO–MPC framework leads to significant improvements in energy efficiency, enhanced dynamic stability, and reduced operational costs under variations in load and flue gas composition. These findings confirm that the integration of predictive control and economic optimization constitutes a promising approach for the sustainable and economically viable operation of industrial CO₂ capture plants.

Keywords: CO₂ capture; Predictive control; Real-time optimization; Aspen dynamics; Control engineering.

LISTA DE ILUSTRAÇÕES

Figura 3. 1 - Fluxograma de uma PCC.....	17
Figura 3. 2 - Funcionamento de um controlador preditivo baseado em modelo	21
Figura 3. 3 - Funcionamento de um controlador preditivo baseado em modelo	24
Figura 3. 4 - Estruturas hierárquicas de integração entre RTO e MPC: a) Estrutura hierárquica de duas camadas com RTO; b) Estrutura hierárquica de três camadas com RTO e c) Estrutura hierárquica de uma camada (MPC econômico)	27
Figura 4.1 - Fluxograma das etapas metodológicas da pesquisa	30
Figura 4. 2 - Fluxograma do processo de captura de CO ₂ de captura de CO ₂ empregado neste trabalho.....	31
Figura 4. 3 - Esquema proposto para plantas de PCC	47
Figura 4.4 - Estratégia de controle.....	33
Figura 5. 1 - Resposta ao degrau para saídas do processo: a) +10% na composição do flegas; b) +10% na vazão de lean; c) +5% vazão de fluegas.....	49
Figura 5. 2 - Implementação de sinais aleatórios de vazão de solvente pobre e composição de CO ₂ dos gases de combustão, Carga térmica das duas torres de stripper para identificação do sistema.....	52
Figura 5. 3 - Comparação entre o Aspen Plus Dynamics® e os modelos de processo identificados....	54
Figura 5. 5 - Entradas Manipuladas 1º caso	58
Figura 5. 6 - Função econômica 1º caso	58
Figura 5. 7 - Saídas controladas 2º caso.....	61
Figura 5. 8 - Entradas Manipuladas 2º caso	61
Figura 5. 9 - Função econômica 2º caso	62
Figura 5.10 - Saídas controladas 3º caso	64
Figura 5.12 - Função econômica 3º caso	65
Figura 5.13 - Métricas de desempenho dinâmicos	65

LISTA DE TABELAS

Tabela 3. 1 Caracterização das correntes de alimentação	33
Tabela 5. 1 - Estado estacionário e parâmetros do PRBS.....	52
Tabela 5. 2 - Preços em termos econômicos, ajustados pela inflação e convertidos para US\$.....	55
Tabela 5. 3 - CLMPC- Movimentos máximos de entrada e saídas	56
Tabela 5. 4 - parâmetros de ajuste CLMPC	56
Tabela 5. 5 - Movimentos máximos de entrada	56
Tabela 5. 6 - parâmetros de ajuste IHMPCFF	57

SUMÁRIO

1. INTRODUÇÃO.....	11
2. OBJETIVOS.....	16
2.1. OBJETIVO GERAL	16
2.2. OBJETIVOS ESPECÍFICOS	16
3. FUNDAMENTAÇÃO TEÓRICA	17
3.1 PROCESSO DE CAPTURA DE CO ₂ DE POS-COMBUSTÃO	17
3.2. ESTRATÉGIAS DE CONTROLE APLICADAS EM PLANTAS DE CAPTURA DE CO ₂	18
3.2.1 Controles Convencionais	19
3.2.2 Controles Preditivos.....	20
3.2.2.1 Linear MPC.....	22
3.2.2.2 Não Linear MPC	23
3.2.2.3 Integração Otimização em Tempo Real (RTO) e MPC.....	24
3.2.2.4 EMPC	28
4. METODOLOGIA.....	30
4.1. SIMULAÇÃO DO PROCESSO EM REGIME TRANSIENTE	30
4.2. ESTRATÉGIA DE CONTROLE	33
4.3. IDENTIFICAÇÃO DO PROCESSO.....	34
4.4. O MODELO ORIENTADO À PREVISÃO DE SAÍDA (OPOM) COM MENSURAÇÃO DOS DISTÚRBIOS	37
4.5. CONTROLADOR PREDITIVO DE MODELO LINEAR AVANÇADO RESTRITO (CLMPC).....	40
4.6. CONTROLADOR IHMPC.....	41
4.6.1 Formulação do IHMPCFF	41
4.7. OBSERVADOR DE ESTADO LINEARES	45
4.8. INTEGRAÇÃO RTO E MPC.....	46
4.9. FORMULAÇÃO RTO	47
5. RESULTADOS E DISCUSSÕES.....	49
5.1 SIMULAÇÃO E IDENTIFICAÇÃO DO PROCESSO	49
5.2. ESTRUTURA DE DUAS CAMADAS DA INTEGRAÇÃO RTO/MPC.....	55
5.2.1 Caso Nominal.....	55
5.2.1.1. CLMPC	56
5.2.1.2 IHMPCFF.....	56
5.2.1.3 Caso Nominal Resultados	57
5.2.2. Caso Mismatch.....	63
6. CONCLUSÃO.....	69
REFERÊNCIAS.....	70

1. INTRODUÇÃO

A situação das emissões globais de dióxido de carbono (CO₂) permanece crítica. O relatório Global Energy Review 2025 da Agência Internacional de Energia (IEA, 2025) indica que as emissões relacionadas à queima de combustíveis fósseis atingiram 37,8 GtCO₂ em 2024, crescendo cerca de 0,8% em relação a 2023, e atingindo concentrações atmosféricas recordes de aproximadamente 422,5 ppm, valor 50% superior aos níveis pré-industriais. De acordo com o relatório do IPCC (2023), cenários compatíveis com o limite de aquecimento global de 1,5 °C exigem reduções rápidas e profundas, com emissões líquidas zero nas próximas décadas e orçamentos de carbono remanescentes cada vez mais restritos.

No que se refere às rotas tecnológicas de captura de CO₂, diferentes abordagens são destacadas na literatura recente. Na pré-combustão, o CO₂ é removido antes da queima através da gaseificação ou reforma (Boot-Handford et al., 2024); na oxidação, o combustível é queimado em oxigênio puro ou enriquecido, produzindo uma corrente de CO₂ e H₂O facilmente separável (Singh et al., 2024); em pós-combustão, o CO₂ é capturado das emissões convencionais de chaminé, sendo a opção mais adequada para *retrofit* em usinas existentes (Chen et al., 2023). Tecnologias emergentes incluem a combustão com chemical looping, que utiliza transportadores sólidos de oxigênio para facilitar a separação intrínseca de CO₂ (Li et al., 2023), e o Direct Air Capture (DAC), que remove CO₂ diretamente da atmosfera, ainda que com elevado custo energético e financeiro (Smith et al., 2024).

Quanto às técnicas de separação, destacam-se: a adsorção em sólidos porosos, como zeólitas e materiais metal-orgânicos (MOFs), que apresentam seletividade elevada (Wang et al., 2023); a absorção líquida, tradicionalmente realizada com solventes químicos como aminas e carbonatos (Patrón & Ricardez-Sandoval, 2023); as membranas poliméricas e híbridas, que vêm sendo otimizadas para maior seletividade e fluxo (Zhang et al., 2024); e os sistemas híbridos, que combinam duas ou mais dessas técnicas para reduzir custos e ampliar a eficiência operacional (Gupta et al., 2024).

Entre todas essas opções, a absorção química com solventes amínicos se mantém como a tecnologia mais consolidada, já operando em escala comercial em processos de pós-combustão (IEA, 2025; Chen et al., 2023). Apesar de sua maturidade tecnológica, seu desafio principal reside no alto consumo energético para regeneração do solvente e na degradação química ao longo do tempo, fatores que elevam o custo operacional. Por esse motivo, diversos estudos recentes vêm integrando modelagem rigorosa do processo e estratégias de controle avançado para mitigar esses efeitos (Patrón & Ricardez-Sandoval, 2023; Wang et al., 2023).

Em sistemas de geração termoeletrica, especialmente aqueles baseados em combustíveis fósseis, a operação é frequentemente caracterizada por variações de carga e intermitência na geração de energia. Essa variabilidade pode ser causada por mudanças na demanda elétrica, estratégias de despacho em sistemas híbridos com renováveis ou oscilações na disponibilidade de combustível. Tais flutuações afetam diretamente as condições de operação do sistema de captura pós-combustão (PCC), resultando em alterações transitórias de vazão, temperatura, pressão e composição do gás de combustão (flue gas) (Lucquiaud & Gibbins, 2020; Reddy et al., 2022).

Sob essas circunstâncias, torna-se evidente que a planta de captura deve ser capaz de responder dinamicamente a perturbações operacionais, mantendo a eficiência de remoção de CO₂ e evitando penalidades energéticas excessivas. Assim, a compreensão e a predição do comportamento transiente são essenciais tanto para o projeto quanto para o controle em tempo real da planta (Mac Dowell & Shah, 2015; Lawal et al., 2012).

Embora existam diversos estudos sobre a modelagem de processos PCC, a maioria dos modelos matemáticos reportados na literatura são validados em estado estacionário, assumindo condições fixas de operação e negligenciando os efeitos de transientes, acoplamentos térmicos e variações de fluxo (Jaya et al., 2013; Bui et al., 2014). Essa limitação impede a avaliação realista do desempenho dinâmico da planta e restringe o desenvolvimento de estratégias de controle robustas para mitigar as oscilações impostas pelo sistema de geração elétrica.

Portanto, o desenvolvimento de modelos em regime transiente, capazes de capturar a interação entre os fenômenos de transferência de massa, calor e reação química sob condições variáveis, é essencial para a otimização e o controle avançado de unidades PCC integradas a usinas de energia. Essa abordagem permite não apenas analisar a resposta da planta a perturbações operacionais, mas também avaliar o impacto dinâmico de estratégias de mitigação de CO₂ em cenários reais de operação flutuante (Mac Dowell et al., 2021; Bui et al., 2024). A modelagem da absorção química é geralmente feita por duas abordagens: modelos baseados em equilíbrio, mais comum na indústria por sua simplicidade (Tsay et al., 2019); e modelos baseados em taxas (*rated-based model*), que oferecem maior precisão (Zhang et al., 2009). A complexidade das reações químicas é um fator crítico na classificação dos modelos baseados em taxas (Chatziasteriou et al., 2022). O uso de softwares, como, por exemplo, o Aspen DynamicsTM, tornou mais precisa a modelagem e a simulação, através da abordagem rigorosa baseada em taxas. Alguns estudos usam os resultados das simulações baseadas em taxas para aprimorar parâmetros, como a eficiência de Murphree, nos modelos baseados em equilíbrio (Robinson & Luyben, 2010; Trapp et al., 2015; Zhang et al., 2016). Outros trabalhos

implementaram modelos dinâmicos baseados em taxas usando softwares customizados, por exemplo, o Aspen Custom Modeler, Matlab® e o gPROMS® (Posch e Haider, 2013; Shen et al., 2019; Harun et al., 2019; Nittaya et al., 2014a, 2014b; Shalaby et al., 2021). Alguns trabalhos usam modelos identificados para descrever a dinâmica, aplicando algoritmos de otimização e estratégias de controle através de funções de transferência, modelos de espaço de estados e algoritmos de aprendizado de máquina (Zhang et al., 2016; Dai et al., 2017; Liang et al., 2018).

Além dos desafios relacionados à modelagem, as unidades de PCC por absorção química apresentam características multivariáveis, não linearidades, efeito “bola de neve” e grandes interações no processo (Luyben et al., 2016). Portanto, as estratégias de controle desempenham um papel crucial na otimização, rejeição de distúrbios e redução dos custos operacionais. Diversas estratégias têm sido propostas para controlar variáveis-chave do processo, tais como a taxa de captura de carbono (%CC) e a temperatura do refulverdor (T_{reb}) em um PCC, sendo comum manipular a vazão de amina pobre e a vazão de vapor do refulverdor para controlar, respectivamente, a %CC e T_{reb} (Lin et al., 2012 a). Com essa estratégia, Gaspar et al. (2015) introduziram perturbações abruptas, variando a vazão de vapor do refulverdor, vazão de amina pobre e vazão de pós-combustão em até $\pm 30\%$. Nittaya et al. (2014 a, b) propuseram três esquemas de controle sujeitos a alterações nos pontos de referência da %CC e perturbações nas condições de operação de pós-combustão (vazão e composição). O estudo concluiu que a estratégia definida por Lin et al. (2012 a) resultou em respostas mais rápidas para rejeitar distúrbios e rastrear os pontos de referência do que outras duas estruturas de controle estudadas.

As estratégias de controle citadas nos trabalhos anteriores se baseiam na ação de controle PID (proporcional-integral-derivativa) do tipo realimentação, razão, cascata e/ou cascata-razão, para lidar com o problema multivariável. Entretanto, essas estratégias não assumem restrições nas variáveis controladas e manipuladas, regulamentações ambientais, mensuração de distúrbios e penalidades energéticas ou econômicas (Salvinder et al., 2019; Zhang et al., 2022). Para superar esses problemas o Controle Preditivo baseado em Modelo (MPC) é utilizado efetivamente em sistemas de captura de CO_2 (Cormos et al., 2015; Zhang et al., 2016). A maioria dos MPCs é aplicado usando modelos lineares contínuos ou discretos, que incluem funções de transferência, espaço de estado e modelos de média móvel autorregressivo com variáveis exógenas (ARMAX) (Arce et al., 2012; Panahi e Skogestad, 2012; Sahraei e Ricardez-Sandoval, 2014; Wu et al., 2018; Mehleri et al., 2019). Modelos não lineares, baseados em sistemas inteligentes ainda possuem poucas ou raras aplicações (Zhang et al.,

2018).

O MPC tem se mostrado eficaz na gestão de sistemas de captura de CO₂, embora muitos desafios permaneçam no desenvolvimento de estratégias de controle avançadas que considerem de maneira abrangente as complexidades do processo (He et al., 2018). Recetemente, Tang & Wu (2023) propuseram um MPC inteligente de controle distribuído para uma unidade de PCC, apesar da relevância do trabalho, limitam-se ao uso de redes neurais sem características recorrentes e um algoritmo de MPC sem horizontes infinitos. Fica evidenciado que os trabalhos com MPC para PCC consideram os modelos de referência sem a mensuração dos distúrbios, variáveis de folga e/ou não consideram dinâmica não-linear. O elevado custo operacional associado às plantas de captura de CO₂ a jusante de usinas de energia representa um dos principais desafios para sua implementação em larga escala. Surge, portanto, a questão central: como recuperar o capital investido e viabilizar economicamente a captura de carbono? Uma das estratégias discutidas na literatura recente é a monetização do CO₂ capturado, seja por meio de sua utilização em processos de Carbon Capture and Utilization (CCU), como a produção de combustíveis sintéticos, ureia ou carbonatos minerais, seja pela participação em mercados de crédito de carbono e mecanismos regulatórios de precificação de emissões (Patrón & Ricardez-Sandoval, 2022; Budinis et al., 2018; IEAGHG, 2021).

Nesse contexto, problemas de função objetivo (F.O.) com restrições econômicas explícitas têm se mostrado ferramentas promissoras tanto para o design quanto para a operação dinâmica de sistemas de captura, permitindo integrar diretamente aspectos econômicos à estratégia de controle. Essa abordagem, denominada controle econômico baseado em modelo (EMPC) ou otimização em tempo real (RTO), possibilita reduzir custos de operação ao mesmo tempo em que assegura estabilidade e eficiência da planta (Ellis & Christofides, 2015; Rawlings et al., 2017).

Assim, a atual fronteira de pesquisa vai além da simples busca pela eficiência termodinâmica da absorção com MEA: trata-se de incorporar objetivos econômicos à dinâmica do processo, garantindo que a captura de CO₂ seja tecnicamente robusta e economicamente sustentável.

Akula et al., (2021) propuseram uma abordagem de Otimização em Tempo Real (RTO) para plantas de absorção com MEA e analisaram o ponto de operação ótimo em cenários de carga parcial, carga total e composição variável de gás de combustão. Patrón et al. (2022) introduziu um esquema inovador para plantas de captura de CO₂ em usinas de energia, combinando otimização em tempo real, controle preditivo não linear e estimação de horizonte móvel. O novo modelo econômico visa reduzir custos, considerando economia de carbono,

energia, químicos e utilidades. Aplicado a uma planta piloto baseada em MEA, o estudo avaliou cenários como co-combustão de carvão e biomassa, variações diurnas de gases e mudanças de preços, demonstrando melhorias significativas na economia de custos e na penalidade energética. No entanto, a algumas limitações que incluem a aplicação em escala piloto, o que pode restringir a generalização dos resultados para plantas industriais, e a necessidade de mais pesquisas para validar a eficácia em diferentes contextos operacionais.

Aqui neste trabalho, apresenta-se como contribuição a construção de controladores preditivos que assumem essas considerações, sendo os controladores preditivos de horizonte infinito (IHMPC) (Darci et al. 2019; Zhang et al., 2018), IHMPCs estendidos com mensuração dos distúrbios (Pataro et al, 2022) com a integração com uma otimização econômica, aplicados em um modelo matemático baseado em uma planta de captura de CO₂ simulada no software *Aspen Plus Dynamics*[®] em conjunto com o Matlab-R2023b[®].

2. OBJETIVOS

2.1. OBJETIVO GERAL

Desenvolver e avaliar o desempenho de algoritmos de controle preditivo, incluindo controladores lineares com ação feedforward, integrados a uma estratégia de otimização econômica, aplicados a uma planta de captura de CO₂ industrial via absorção química.

2.2. OBJETIVOS ESPECÍFICOS

Para que o objetivo geral seja alcançado, alguns objetivos específicos devem ser desenvolvidos:

- Exportar uma planta de captura de CO₂ via absorção química em estado estacionário, previamente simulada no Aspen PlusTM por Jesus et al. (2022), para o regime transiente no Aspen DynamicsTM;
- Coletar dados e identificar o processo para desenvolver modelos multivariáveis na forma de funções de transferências, espaço de estado e modelos orientado à predição de saída (OPOM);
- Construir algoritmos de controladores preditivos com horizonte finito e infinito (H_{∞});
- Integrar os controladores de modelo preditivo (MPC) com a otimização em tempo real (RTO), MPC+RTO;
- Avaliar a capacidade preditiva dos controladores, checando parâmetros qualitativos e quantitativos das respostas e variáveis manipuladas;

O gás de combustão previamente tratado segue para a seção de lavagem com MEA, cuja finalidade é minimizar a perda de solvente por arraste. Nessa etapa, a amina absorvida é recuperada e posteriormente reciclada tanto para o absorvedor quanto para a própria seção de lavagem, contribuindo para a redução de custos operacionais e mitigação de emissões. Na parte inferior do absorvedor, o solvente rico em CO₂ é bombeado em direção ao topo da coluna de stripper. Antes de sua entrada, o fluxo passa por um trocador de calor integrado (cross heat exchanger), no qual é pré-aquecido até uma temperatura próxima à de operação da desabsorvedora. Essa estratégia de integração energética permite reduzir significativamente a demanda de vapor no reboiler, aumentando a eficiência térmica global do processo. Em contrapartida, o solvente pobre proveniente do stripper é resfriado nesse mesmo equipamento, retornando a uma condição adequada para a absorção de CO₂ no contato com os gases de combustão. (Rochelle, 2009; Le Moullec & Kanniche, 2011; IEAGHG, 2019). Três principais variáveis para a operação e o controle de uma planta de captura pós-combustão incluem: a taxa de captura de CO₂ (% CC), geralmente controlada com um controle razão entre a vazão de CO₂ do *flue gas* e a vazão que CO₂ sai do sistema de lavagem, manipulando-se a vazão de solvente recuperado; a temperatura do reboiler (T_{REB}), sendo a vazão de vapor que deixa o reboiler a variável manipulada; e o consumo energético para a remoção de CO₂ é significativa, haja vista que vapor de baixa pressão deve ser fornecido para regenerar o solvente no reboiler da torre de stripper.

3.2. ESTRATÉGIAS DE CONTROLE APLICADAS EM PLANTAS DE CAPTURA DE CO₂

O controle em processos de captura de CO₂ desempenha um papel central tanto na eficiência operacional quanto na conformidade regulatória das plantas industriais. O sistema de controle deve atuar em diferentes níveis: na etapa de absorção, assegurando o contato adequado entre o solvente e o gás de combustão; na etapa de desorção, garantindo a regeneração eficiente do solvente; e no controle das condições reacionais (temperatura, pressão e composição), de modo a manter a estabilidade do processo e minimizar emissões fugitivas de CO₂ (Gaspar et al., 2015; Gaspar et al., 2016).

Nas últimas décadas, o avanço das estratégias de controle tem permitido a implementação de abordagens multivariáveis e preditivas, capazes de lidar com a forte não linearidade e o alto acoplamento entre variáveis típicas de sistemas de captura. O controlador de modelo preditivo (MPC), por exemplo, tem sido amplamente estudado por sua capacidade de operar de forma proativa diante de restrições de processo, otimizando o desempenho global

e reduzindo o consumo energético (Sharifzadeh et al., 2019; Li et al., 2012).

Além disso, a aplicação de estruturas hierárquicas de controle, que combinam malhas regulatórias convencionais com camadas superiores de otimização em tempo real, tem se mostrado eficaz para integrar objetivos econômicos e ambientais ao desempenho dinâmico do processo (Nyttaya et al., 2014; Bristol, 1996). Dessa forma, o controle avançado não apenas assegura uma captura eficaz de CO₂, mas também contribui de maneira estratégica para a redução das emissões globais de gases de efeito estufa, reforçando o papel da captura de carbono na transição para uma economia de baixo carbono.

3.2.1 Controles Convencionais

Lin et al. (2012) propuseram duas estratégias de controle PI para o sistema integrado de PCC. Na primeira estratégia, o fluxo de solvente magro foi usado para controlar o nível de captura e o fluxo de vapor foi usado para controlar a temperatura do reboiler. Na segunda estratégia, o fluxo de solvente magro foi mantido constante e o nível de captura foi controlado através do fluxo de vapor.

Mechleri et al. (2017) testaram a flexibilidade operacional e o desempenho econômico de duas estratégias de controle de PCC em caso de ampla variação de carga de usinas termelétricas a carvão e a gás natural. O desempenho de um esquema operacional que alternava dinamicamente entre os dois modos de controle mencionados acima também foi avaliado.

Nittaya et al. (2014) compararam estruturas de controle descentralizado convencionais de PCC com outra estrutura que associava o nível de captura com o fluxo de vapor do reboiler e a temperatura do reboiler com o fluxo de solvente rico. O desempenho dos esquemas de controle foi avaliado em diferentes cenários, como mudanças na taxa de fluxo de gás de combustão, mudanças no ponto de ajuste do nível de captura e aderência da válvula de fluxo de solvente magro.

As estratégias de controle convencionais para a captura de CO₂ (PCC) apresentam várias limitações que destacam a necessidade de abordagens mais avançadas. Primeiramente, estudos como o de Rodriguez et al. (2014) mostram que essas estratégias podem ter uma resposta lenta a perturbações significativas, levando tempo para que o nível de captura de CO₂ e outras variáveis atinjam um novo estado de equilíbrio após mudanças operacionais. Além disso, a não linearidade do processo de PCC e a forte dinâmica do sistema podem dificultar o controle eficaz sob condições operacionais variáveis, como mudanças na carga da usina termelétrica, conforme discutido por Gaspar et al. (2015).

Outra limitação é a possível ocorrência de oscilações e overshoots nas variáveis

controladas, como observado nos estudos de Lawal et al. (2010) e Lin et al. (2011), que apontam que a estrutura de controle convencional pode, sob certas condições, resultar nesses comportamentos indesejáveis. Além disso, a falta de consideração das interações entre a usina termelétrica e o processo de captura de CO₂, como observado por Lawal et al. (2012), pode levar a oscilações e desempenho subótimo do sistema de controle.


3.2.2 Controles Preditivos

O controle preditivo baseado em modelo (MPC) aplicado em plantas de captura de carbono já é bastante difundido na literatura, na qual o MPC é uma categoria de estratégias de controle que emprega um modelo explícito do processo para antecipar respostas futura da planta em diversas sequências de entrada. A otimização de uma função objetivo dinâmica é então aplicada para determinar a melhor sequência de entrada a ser seguida (Qin et al., 2003). É um dos poucos métodos de controle que leva em consideração diretamente as restrições.

O princípio do MPC consiste na utilização de um modelo preditivo do processo para estimar o comportamento futuro das variáveis de saída dentro de um intervalo denominado horizonte de predição (HP). Com base nessas predições, o controlador resolve, em cada instante de tempo, um problema de otimização que minimiza uma função objetivo. Essa função penaliza tanto os desvios das saídas em relação às referências quanto as variações nas entradas manipuladas, garantindo uma operação estável e eficiente (RAWLINGS e MAYNE, 2009).

O MPC adota uma abordagem a cada etapa de controle apenas a primeira ação da sequência ótima calculada é aplicada ao processo, e o problema de otimização é resolvido novamente no próximo passo, utilizando informações atualizadas do sistema. Isso permite ao controlador reagir de forma dinâmica às perturbações e mudanças nas condições operacionais (QIN e BADGWELL, 2003). A Figura 3.2 exemplifica como o controlador MPC atua.

Figura 3. 2 - Funcionamento de um controlador preditivo baseado em modelo



Fonte: Adaptada de Maciej Ławryńczuk (2009).

Entretanto, a eficácia de um MPC (ou de qualquer outra abordagem fundamentada em modelos) está intrinsecamente ligada à precisão do modelo do processo e à sintonia dos parâmetros do controlador. Previsões imprecisas podem, na verdade, deteriorar o desempenho global da planta em vez de aprimorá-lo (Seborg et al., 2011).

Além disso, considerando os sistemas de captura de CO₂ pós-combustão (PCC), a escolha adequada das variáveis controladas e manipuladas é fundamental para garantir a estabilidade operacional, a eficiência energética e a segurança do processo. De forma geral, as variáveis controladas correspondem às grandezas que definem o desempenho da planta, enquanto as variáveis manipuladas são aquelas ajustadas pelo controlador para manter as metas desejadas dentro das restrições de operação (Lawal et al., 2012; Bui et al., 2018).

Entre as variáveis controladas mais comuns destacam-se:

- a taxa de captura de CO₂, que reflete diretamente a eficiência do sistema;
- a temperatura de topo e de fundo das colunas de absorção e dessorção, que impactam o equilíbrio de fases e a regeneração do solvente;
- e a composição de CO₂ na corrente de saída, que deve atender aos limites ambientais e de purificação estabelecidos (Gaspar et al., 2016; Reddy et al., 2022).

As principais variáveis manipuladas incluem:

- a vazão de solvente pobre (MEA) enviada à coluna de absorção;
- a carga térmica aplicada ao reboiler do stripper, responsável pela regeneração do solvente;

- e, em alguns casos, a vazão de gás de combustão (flue gas) ou a temperatura de entrada do gás, quando há integração com o sistema de geração de energia (Lucquiaud & Gibbins, 2020; Patrón & Ricardez-Sandoval, 2022).

Essas variáveis estão fortemente interligadas por relações não lineares de balanço de massa e energia, o que justifica o uso de controladores multivariáveis avançados, como o MPC, capazes de lidar simultaneamente com as restrições operacionais e os acoplamentos dinâmicos entre temperatura, fluxo e composição.

3.2.2.1 Linear MPC

O MPC linear, baseado em um modelo linear do processo, é reconhecido por sua maturidade técnica e robustez computacional, permitindo lidar com cálculos complexos de forma eficiente, essencial para o controle em tempo real de processos industriais como o PCC. Diversos estudos na literatura exploram a aplicação dessas estratégias no processo de captura de CO₂. O primeiro estudo de MPC no PCC foi realizado por Bedelbayev et al. (2008), focando no controle de um absorvedor individual. Eles linearizaram um modelo complexo de primeiros princípios em um ponto de operação específico e utilizaram como modelo preditivo do MPC, controlando a concentração de CO₂ no gás ventilado e manipulando a velocidade do solvente pobre, além de incluir variáveis como a velocidade do gás de entrada e a temperatura para melhorar o desempenho do MPC.

Sahraei e Ricardez-Sandoval (2014) apresentaram um MPC para a operação flexível do PCC, usando dados de simulações em malha aberta do modelo ASPEN HYSYS® para identificar modelos lineares de primeira ordem, transformando-os em modelos de espaço de estados. As simulações demonstraram que o MPC poderia atingir uma resposta superior em comparação com um controle de feedback descentralizado convencional.

Mehleri et al. (2015) avaliaram a controlabilidade do PCC com MPC, usando um modelo MIMO de espaço de estados. Os resultados mostraram que o MPC ofereceu uma boa opção para a operação do PCC em termos de rejeição de perturbações e rastreamento do ponto de ajuste.

Luu et al. (2015) projetaram um MPC linear para controlar o nível de captura de CO₂ e o desempenho energético do PCC, utilizando a taxa de fluxo do solvente pobre e a capacidade de calor do reboiler como variáveis manipuladas. Comparações com controladores PID descentralizados destacaram as vantagens do MPC em lidar com restrições operacionais.

Alguns estudos, como os de Zhang et al. (2016) e Wu et al. (2018, 2019), consideraram apenas o ajuste do nível de captura de CO₂ e a temperatura do reboiler, manipulando a taxa de

fluxo do solvente pobre e a taxa de fluxo de vapor do reboiler, focando nas variáveis mais importantes do PCC. Zhang et al. (2016) desenvolveram um controlador de MPC linear via MATLAB® MPC Toolbox, mostrando melhor desempenho do que o controlador PID no controle do nível de captura. Wu et al. (2018) desenvolveram um MPC linear para a operação flexível do PCC, mostrando melhor desempenho no rastreamento do nível de captura em comparação com a estrutura de controle PI convencional.

Estudos recentes de Wu et al. (2019) projetaram MPCs para a operação integrada do sistema CFPP-PCC, desenvolvendo um MPC centralizado para controlar as variáveis-chave dentro do sistema CFPP-PCC e um sistema de controle coordenado composto por dois MPCs, um para o CFPP e outro para o PCC, propondo diferentes modos operacionais para melhor alcançar as funções do sistema CFPP-PCC.

3.2.2.2 Não Linear MPC

Desenvolvido com base em um modelo linear do processo, o MPC linear é uma técnica madura e oferece vantagens em termos de computação eficiente e robusta, sendo amplamente utilizado no controle de PCC. No entanto, com a crescente demanda por operações flexíveis, o sistema PCC precisa lidar com a variação do gás de combustão e ajustar seu nível de captura de CO₂ em uma ampla faixa. Durante essa transição, outras variáveis dentro do sistema PCC, como a temperatura do reboiler, podem mudar significativamente. À medida que essas variáveis-chave se desviam das condições projetadas, a dinâmica da planta mudará e exibirá um comportamento fortemente não linear. Como o modelo linear desenvolvido em torno de um ponto de operação específico pode não ser mais suficiente para refletir o comportamento do PCC nessa situação, é inevitável usar o MPC não linear para melhorar o desempenho operacional do PCC.

Åkesson et al. (2011, 2012) propuseram o primeiro MPC não linear para o processo de PCC. Para desenvolver um modelo apropriado eficiente para o cálculo online do MPC, o modelo complexo do processo PCC foi simplificado substituindo as reações químicas na fase líquida por uma tabela interpolada contendo dados de equilíbrio. Dois MPCs não lineares foram então projetados com base no modelo, visando controlar a eficiência de captura de CO₂ do PCC. Um MPC usou o dever do reboiler como a única MV, enquanto o dever do reboiler e a taxa de recirculação do solvente foram selecionados como MVs no outro MPC Åkesson et al. (2012). Os resultados indicaram a viabilidade do MPC não linear no processo de PCC e mostraram que era essencial controlar o processo de PCC manipulando a taxa de circulação do solvente.


Zhang et al. (2019) desenvolveram um MPC não linear para o processo de PCC usando

um modelo autoregressivo aditivo não linear com entradas exógenas (NAARX). O modelo NAARX identificado é superior ao modelo linear na previsão de nível de captura em ampla faixa e na previsão de temperatura do reboiler, resultando em melhor desempenho do MPC não linear em comparação com o MPC linear. No entanto, a melhoria foi muito limitada, pois foi desafiador selecionar termos cruzados adequados do modelo NAARX para aprimorar ainda mais a precisão da aproximação.

Para superar a não linearidade do processo PCC, Wu et al. (2018) propuseram uma estratégia de controle preditivo multimodelo para operação flexível em ampla faixa do PCC. Três MPCs lineares locais, desenvolvidos em regiões de baixo, médio e alto nível de captura de CO₂, foram combinados e programados através de uma função de pertinência determinada pelo nível de captura atual. As simulações mostraram que o sistema de controle preditivo multimodelo controlou a planta PCC melhor do que o MPC linear, alcançando uma mudança rápida e suave no nível de captura de CO₂ em uma ampla faixa de operação.

3.2.2.3 Integração Otimização em Tempo Real (RTO) e MPC

Figura 3. 3 - Funcionamento de um controlador hierárquico



Fonte: o autor.

Na arquitetura de controle considerada, a hierarquia é composta por quatro níveis

principais (Figura 3.3). No nível mais baixo, atuam os controladores regulatórios convencionais (PID), garantindo a estabilidade básica do processo em horizontes de segundos a minutos. Em seguida, o controle preditivo baseado em modelos (MPC) opera em horizonte de minutos, ajustando as variáveis manipuladas de forma multivariável e antecipatória. No terceiro nível, insere-se a otimização em tempo real (RTO), cuja função é calcular o ponto ótimo econômico da planta em horizontes de minutos a horas, por exemplo considerando custos energéticos, preço do CO₂, carga de vapor disponível e restrições operacionais. Esse nível envia os setpoints ótimos ao MPC, que assegura a convergência dinâmica. Por fim, no quarto nível, o planejamento de produção define metas de longo prazo (dias a semanas), relacionadas a logística e compromissos contratuais.

Existem diversas estratégias e estruturas propostas na literatura para a integração entre a Otimização em Tempo Real (RTO, Real-Time Optimization) e o Controle Preditivo Baseado em Modelo (MPC, Model Predictive Control). A abordagem clássica corresponde à estrutura hierárquica em múltiplas camadas, em que o RTO e o MPC são executados em diferentes níveis da malha de controle (Marlin & Hrymak, 1996; Alamo et al., 2012), mostrado na (Figura 2. 4).

Na estrutura de duas camadas, o RTO ocupa o nível superior da hierarquia e é responsável por determinar os pontos ótimos de operação econômica do processo, com base em um modelo estacionário não linear. Essa camada é executada com uma frequência mais lenta (da ordem de horas a dias) e fornece setpoints econômicos ao controlador MPC localizado na camada inferior. O MPC, por sua vez, utiliza um modelo linear dinâmico do processo para direcionar o sistema às metas fornecidas pelo RTO, respeitando as restrições operacionais e garantindo estabilidade e suavidade de resposta. Essa estrutura é amplamente empregada em processos industriais, mas apresenta limitações em situações de transientes operacionais ou perturbações rápidas, uma vez que o RTO assume condições estacionárias que podem gerar inconsistências entre os modelos estático e dinâmico (Alamo et al., 2014; Rotava & Zanin, 2005).

Uma variação dessa estrutura é o RTO de três camadas, que inclui uma camada intermediária de otimização linear entre o RTO e o MPC. Essa camada atua como elo de compatibilidade, ajustando as diferenças entre o modelo não linear do RTO e o modelo linear do controlador, reduzindo a divergência entre as metas econômicas e as restrições dinâmicas (Rotava & Zanin, 2005).


Mais recentemente, evoluiu-se para o conceito de RTO de camada única, também conhecido como Economic MPC (EMPC) ou RTO integrado, no qual as funções de otimização econômica e controle dinâmico são unificadas em um único problema. Nesse caso, a função

custo do MPC incorpora diretamente o termo econômico, substituindo a otimização estacionária da camada RTO tradicional. Assim, o EMPC calcula ações de controle que são simultaneamente ótimas do ponto de vista dinâmico e econômico, com base em medições em tempo real. Essa estrutura elimina a defasagem temporal entre as camadas de otimização e controle, permitindo respostas mais rápidas e eficientes frente a perturbações e variações operacionais (De Souza et al., 2010; Porfírio & Odloak, 2011; Esturilio, 2012).

Contudo, o RTO de camada única apresenta maior complexidade computacional, uma vez que o problema de otimização é, em geral, não linear (NLP). Para contornar essa limitação, abordagens baseadas em gradientes econômicos foram propostas, simplificando o problema para programação quadrática (QP), o que reduz o custo computacional mantendo resultados próximos aos obtidos com a formulação completa (Alamo et al., 2012; De Souza et al., 2010).

No contexto da planta de captura de CO₂ pós-combustão com MEA, a escolha entre estruturas de uma ou duas camadas depende das condições de operação e da flexibilidade exigida. Sob condições quase estacionárias e regime contínuo, o RTO de duas camadas é suficiente para garantir o equilíbrio entre eficiência energética e desempenho de captura. No entanto, sob condições transientes — como variações na vazão de flue gas, na composição de CO₂ e na carga térmica do stripper — o RTO de camada única (EMPC) apresenta melhor desempenho dinâmico, uma vez que ajusta as metas econômicas e as variáveis manipuladas de forma simultânea e preditiva.

Figura 3. 4 - Estruturas hierárquicas de integração entre RTO e MPC: a) Estrutura hierárquica de duas camadas com RTO; b) Estrutura hierárquica de três camadas com RTO e c) Estrutura hierárquica de uma camada (MPC econômico)



Fonte: o autor.

Há vários trabalhos na literatura com estratégias com essa estrutura, como feito por Arce et al. (2012) propuseram uma estrutura de controle hierárquico de dois níveis para o stripper do PCC para minimizar o custo operacional da regeneração do solvente. No nível superior, o controle determinava o ponto de ajuste econômico Taxa de captura de CO_2 , resolvendo um problema de otimização em estado estacionário com base no preço do CO_2 e Consumo energético da planta. Dois controladores preditivos generalizados (GPC) foram desenvolvidos no nível inferior para rastrear os pontos de ajuste ótimos. O primeiro GPC controlava a pressão do *reboiler* manipulando a vazão molar de vapor, incluindo as restrições de temperatura do *reboiler*. O segundo GPC controlava taxa de captura de CO_2 e o nível do *reboiler* manipulando o fluxo de entrada do solvente e o fornecimento de calor, considerando o fluxo de saída do solvente como uma perturbação medida. Resultados de simulação mostraram que o

GPC poderia responder mais rapidamente do que o controle PID convencional e eliminar melhor os efeitos das perturbações. Manaf et al. (2016) propuseram um método de controle ágil para a tecnologia de captura de CO₂, visando maximizar a receita líquida operacional. Essa abordagem permite uma adaptação rápida e eficaz do sistema de captura de CO₂ às mudanças nas condições operacionais, resultando em uma operação mais rentável e eficiente. Manaf et al. (2017) apresentaram um algoritmo híbrido MPC-MINLP para a operação ótima de usinas termelétricas a carvão com captura pós-combustão de CO₂ baseada em solventes. Essa abordagem integrada de controle e otimização visa maximizar a receita líquida da planta, considerando tanto a eficiência da captura de CO₂ quanto os custos operacionais, contribuindo para uma operação mais econômica e sustentável.

Patrón et al. (2020) fez uma combinação Otimização em Tempo Real (RTO), Controle Preditivo Não Linear (NMPC) e Estimação com Filtro de Kalman (KF) para plantas MEA resultou em uma redução de custos de cerca de 10% em cenários de variação diurna e de imposto de carbono. Contudo a consideração dos custos foi limitada aos solventes, imposto de carbono e custos de bombeamento, com manipulação apenas da vazão para o absorvedor.

Patrón et al. (2022) aprimorou o estudo de 2020, apresentou um esquema operacional inovador para plantas de captura de CO₂ pós-combustão (PCC) em usinas de energia. A abordagem proposta combina otimização em tempo real, controle preditivo não linear e estimação de horizonte móvel para operar o sistema de forma econômica. Um novo modelo econômico é desenvolvido para incentivar a redução de custos, considerando aspectos econômicos significativos da captura de CO₂, como economia de carbono, custos de energia, químicos e utilidades. O estudo foi aplicado a um estudo de caso em escala piloto de uma seção absorvedora baseada em MEA, com aproximações dos efeitos da seção de stripper. Diferentes cenários foram avaliados, incluindo a co-combustão de carvão e biomassa, variação diurna nas quantidades de gases de combustão e mudanças de preços. Os resultados mostraram melhorias consistentes na economia de custos em estado estacionário e na penalidade energética associada

3.2.2.4 EMPC

He et al. (2016) ampliaram o trabalho Sahraei e Ricardez-Sandoval (2014) ajustando dinamicamente os pesos do MPC na otimização da programação, aproximando a estrutura integrada de programação e controle de um MPC econômico, que calcula diretamente a sequência de controle ótima minimizando dinamicamente uma função objetivo econômica. He et al. (2018) compararam o desempenho do MPC não linear, do DMC linear e dos controladores PID para configurações de PCC convencional e de compressão de vapor pobre. Manter o nível

de captura de carbono em 90% sob a mudança na taxa de fluxo de gás de combustão foi o principal objetivo do MPC, mas o consumo de energia também foi considerado na função objetivo para melhorar o desempenho econômico. Os MPCs foram implementados com sucesso e mostraram ter um desempenho de controle muito superior em comparação com o controle PID. No entanto, como diferentes funções objetivo foram usadas para o DMC e o MPC não linear, as comparações entre eles foram injustas. He e Lima (2019) modificaram o MPC não linear incluindo a penalidade das ações da MV e o controle da carga do solvente pobre na função objetivo. Simulações em um processo de PCC convencional sob mudança na taxa de fluxo de gás de combustão demonstraram a eficácia do MPC não linear em rastrear/manter o nível de captura de CO₂ desejado. O MPC não linear superou o DMC linear, pois o desajuste do modelo linear aumentou durante a mudança nas condições operacionais.


Em vez de usar o MPC para rastrear os pontos de ajuste desejados, Chan et al (2019) propuseram uma estratégia de controle preditivo de modelo econômico (EMPC) para a operação do PCC. O desempenho econômico, como o custo do solvente MEA e o uso de energia para bombas e reboilers, foi diretamente considerado na função objetivo. As sequências futuras de taxa de fluxo do solvente e dever do reboiler, que poderiam alcançar o melhor desempenho econômico dentro do horizonte preditivo, foram calculadas através da otimização dinâmica. Comparado com a estrutura de design convencional composta por otimização de ponto de ajuste em estado estacionário e controle de rastreamento de ponto de ajuste dinâmico, o EMPC tem uma estrutura simples e pode lidar melhor com as perturbações na otimização. Menor custo de captura de CO₂ foi encontrado com a implementação do EMPC.

O trabalho de Decardi-Nelson et al (2018) propôs um método de controle preditivo econômico para melhorar a flexibilidade e eficiência energética de plantas de captura de CO₂ pós-combustão. Eles integram a otimização econômica ao controle do processo de captura de CO₂, visando reduzir custos operacionais e otimizar o desempenho da planta. A abordagem proposta visa melhorar a eficiência operacional e a flexibilidade da planta, contribuindo para uma operação mais econômica e sustentável. Onde a combinação de Controle Preditivo Baseado em Modelo (EMPC) e Otimização em Tempo Real (RTO) para plantas MEA resultou em uma economia de custos de cerca de 6% em comparação com um ponto de operação constante. Distúrbios no fluxo de gás de combustão e no preço do vapor foram considerados.

4. METODOLOGIA

O fluxograma da Figura 4.1 apresenta a metodologia desenvolvida no trabalho. Cada uma das etapas da Figura 4.1 será descrita nas seções seguintes.

Figura 4.1 - Fluxograma das etapas metodológicas da pesquisa




Fonte: o autor.

4.1. SIMULAÇÃO DO PROCESSO EM REGIME TRANSIENTE



O objeto de estudo deste trabalho é uma planta de captura de carbono projetada para remover dióxido de carbono de uma usina termelétrica a óleo combustível com alta capacidade de geração. Essa planta foi concebida e simulada em regime estacionário no *software* Aspen Plus™ por Jesus et al. (2022). No estudo, os autores desenvolveram três alternativas de fluxogramas de engenharia e selecionaram a mais adequada com base na taxa de captura de CO₂ e na análise econômica do processo. O fluxograma considerado mais eficiente, ilustrado na Figura 4.2, é o adotado neste trabalho.

Figura 4.2- Fluxograma do processo de captura de CO₂ de captura de CO₂ empregado neste trabalho




Fonte: Jesus et al. (2022)

A absorção reativa do sistema CO₂-MEA-H₂O envolve múltiplos equilíbrios e reações cinéticas reversíveis. As reações de equilíbrio envolvidas no modelo são:



Além disso, as reações neste modelo que envolvem cinéticas podem ser expressas como:



Para a modelagem reativa do processo de absorção-recuperação de CO₂, foi adotado o módulo RadFrac do Aspen Plus®, que corresponde a um modelo rigoroso de colunas de equilíbrio e reatividade, sem simplificações empíricas em sua formulação. Esse modelo é amplamente utilizado em operações de fracionamento multicomponente envolvendo fases líquido-vapor, sendo capaz de representar colunas recheadas ou em estágios discretos, com

qualquer número de pratos teóricos e fluxos secundários de produto (AspenTech, 2023).

Nas colunas de absorção e stripping, foi aplicado o *Rate-Based Model* (RBM), uma abordagem mais fundamentada do ponto de vista físico-químico em relação aos modelos de estágio em equilíbrio. Diferentemente do modelo de equilíbrio (*Equilibrium Stage Model*), o modelo baseado em taxas (*Rate-Based Model*) considera explicitamente as taxas de transferência de massa, calor e reação química ao longo da coluna, dispensando a suposição de equilíbrio instantâneo entre as fases (Taylor & Krishna, 1993; Kister, 1992). Essa abordagem é particularmente adequada para sistemas reativos e fortemente não ideais, como o sistema CO₂–MEA–H₂O, em que a resistência difusiva e a cinética de reação têm papel determinante na performance global do processo.

O modelo *Rate-Based* utilizado assume a existência de equilíbrio local nas interfaces das fases e faz uso de correlações fenomenológicas para estimar os coeficientes de transferência de massa e calor. O equilíbrio termodinâmico líquido–vapor foi descrito pelo modelo γ – ϕ , que combina o coeficiente de atividade no líquido (γ) com o coeficiente de fugacidade no vapor (ϕ). O cálculo de γ foi realizado pelo modelo *Electrolyte Non-Random Two-Liquid* (e-NRTL) proposto por Chen et al. (1982), amplamente reconhecido por sua precisão na representação de soluções eletrolíticas fortemente associadas, como as formadas por aminas aquosas. Já o coeficiente de fugacidade ϕ foi obtido pela equação de estado de Redlich–Kwong, adequada para gases em condições moderadas de pressão.

As propriedades físicas e de transporte do sistema foram estimadas seguindo as correlações de Austgen et al. (1989) e Pacheco (1998), que consideram explicitamente os efeitos da concentração de amina, temperatura e carga de CO₂ na viscosidade, difusividade e condutividade térmica da solução. O Aspen Plus® fornece internamente os parâmetros adicionais necessários à solução numérica do modelo, permitindo a convergência termoquímica do processo completo.

A planta simulada foi composta por três colunas de absorção (A-101, A-102 e A-103), um trocador de calor de integração energética (HX-101), um resfriador (HX-102) e duas colunas de stripping (D-101 e D-102). Os principais dados de projeto e os resultados obtidos na simulação encontram-se apresentados na Tabela 3.1.

Tabela 3. 1 Caracterização das correntes de alimentação

Parâmetros Para Alimentação				
Corrente	Flue gas	Lean amine	H₂O Make-up	MEA Make-up
TEMPERATURA [K]	319,7	314	298	298
PRESSÃO [kPa]	104,7	103,5	103,5	103,5
V MOLAR [kmol/s]	20,1	110,1	0,8	0,002
CO ₂ (FRAC MOL)	0,163	0,036	0	0
MEA (FRAC MOL)	0	0,124	0	1
H ₂ O (FRAC MOL)	0,025	0,840	1	0
N ₂ (FRAC MOL)	0,793	0	0	0
O ₂ (FRAC MOL)	0,019	0	0	0
Equipamento	D [M]	H [M]	Recheio	Nº De Estágios
ABSORVEDOR 1	11,80	16,50	IMTP#50	20
ABSORVEDOR 2	11,80	16,50	IMTP#50	20
ABSORVEDOR 3	11,80	16,50	IMTP#50	20
STRIPPER 1	10,40	16,00	IMTP#50	20
STRIPPER 2	10,40	16,00	IMTP#50	20

Fonte: Jesus et al. (2022).

A planta foi simulada no Aspen Dynamics™, utilizando o modo flow-driven para obtenção dos dados em regime transiente. Todos os controles foram removidos, permitindo a simulação em malha aberta. Inicialmente, realizou-se uma simulação com resposta ao degrau para analisar o comportamento do processo, em seguida, foi feita outra simulação de 20 horas para coleta dos dados necessários

4.2. ESTRATÉGIA DE CONTROLE

A Figura 4.3 ilustra a arquitetura de controle e otimização proposta para uma planta de captura de CO₂ pós-combustão (PCC), estruturada em duas camadas hierárquicas. Na camada superior, o módulo de Otimização em Tempo Real (RTO) resolve, em horizonte de médio a longo prazo, um problema de otimização econômica baseado em modelos estacionários, considerando custos energéticos, penalidades por emissões e receitas associadas à captura de CO₂. Os setpoints econômicos ótimos gerados pelo RTO são enviados à camada inferior.

A camada inferior é composta por um controlador preditivo baseado em modelo (CLMPC/IHMPC), responsável pelo controle dinâmico do processo em horizonte curto, garantindo o rastreamento dos setpoints fornecidos pelo RTO, o atendimento às restrições operacionais e a rejeição de perturbações. O controlador utiliza um modelo orientado à previsão da saída (FT/OPOM), alimentado por medições do processo e estimativas de estado, para prever o comportamento futuro da planta.

As ações de controle são aplicadas diretamente à planta de PCC, enquanto as medições

retornam ao modelo de predição e ao RTO por meio de um observador de estado, fechando o ciclo de realimentação. Essa integração permite a operação contínua da planta próxima ao ótimo econômico, conciliando desempenho dinâmico, robustez e eficiência energética.


Sendo:

$$y = \begin{bmatrix} y_1 = \text{Taxa de captura} \\ y_2 = \text{TREB} - D101 \\ y_3 = \text{TREB} - D102 \end{bmatrix}$$

$$\Delta u = \begin{bmatrix} MV1 = \text{vazão de solvente pobre} \\ MV2 = \text{Carga térmica do refeedor da coluna D - 101} \\ MV3 = \text{Carga térmica do refeedor da coluna D - 102} \end{bmatrix}$$

$$\Delta d = [\text{composição de gás de CO}_2 \text{ no } \textit{flue gas}, \text{vazão de } \textit{flue gas}]$$

Figura 4.3 - Estratégia de controle



Fonte: o autor.

4.3. IDENTIFICAÇÃO DO PROCESSO

Antes da implementação do MPC, o modelo Aspen Plus Dynamics® precisa ser identificado como um modelo apropriado. O modelo usado no MPC deve representar o comportamento dinâmico do modelo Aspen Plus Dynamics®. Deseja-se usar sinais de sequência binária pseudoaleatória (PRBS) para obter as saídas para identificação do sistema.

No entanto, descobriu-se que o modelo Aspen Plus Dynamics® pode falhar na convergência quando os sinais PRBS são introduzidos para excitação do sistema. Para resolver esse problema, os sinais são gerados pelo Gerador de Sinais PRBS no Aspen Plus Dynamics®, mas a amplitude do sinal é definida como variável (valor aleatório entre 0 e 1) em vez de 0 ou 1, a cada passo para garantir a convergência do modelo Aspen Plus Dynamics® sobre a sequência testada.

Com relação ao sinal de excitação escolhido para a etapa de identificação a sequência binária pseudoaleatória (PRBS) (LJUNG, 1999), Equação (4.1). O período P de um sinal PRBS gerado por um registrador de ordem n com polinômio primitivo é dado por $P = 2^n - 1$ (OGUNNAIK et al., 1994).

$$u(k+1) = \sum_{j=1}^n b_j u(k-j), XOR \quad (4.1)$$

Onde: $u(k) \in \{0,1\}$ é a saída binária da sequência no instante k ;

$b_i \in \{0,1\}$ são os coeficientes da realimentação (definindo o polinômio gerador);

n é a ordem do registrador;

XOR significa dizer que operação é realizada em aritmética módulo 2.

Como a duração total do sinal PRBS, também chamada de período da sequência (T_s), é dada pelo produto $T_s = P \cdot t_b$, onde t_b é o tempo de bits (duração) do sinal PRBS, foi feito teste de grau realizado para determinação deste parâmetro. A premissa parte da seguinte regra prática (LJUNG, L., 1999),

$$0,1\tau_{min} \leq t_b \leq 0,2\tau_{min} \quad (4.2)$$

Além disso, a excitação das variáveis manipuladas foi realizada de forma simultânea em uma única simulação transiente. Para garantir a independência entre os sinais e evitar correlação entre entradas, cada variável foi excitada com um sinal PRBS configurado com tempo de bit distinto. Essa estratégia aumenta a persistência de excitação do sistema, assegura melhor identificação das interações multivariáveis e reduz o esforço computacional, uma vez que os dados necessários para ajuste dos modelos foram obtidos em uma única execução da simulação. Além disso, o uso de diferentes tempos de bit permite que cada variável manipulada

explore faixas de frequência distintas, enriquecendo a base de dados para estimação de modelos multivariáveis, fundamentais para a implementação futura de estratégias de controle preditivo econômico.

Após a obtenção dos dados de entrada e saída por meio da excitação do sistema com sinais PRBS, torna-se necessário realizar o pré-processamento dos dados antes da etapa de identificação do modelo dinâmico. Entre as etapas de pré-processamento, a normalização das variáveis assume papel fundamental, especialmente em sistemas multivariáveis com grandezas físicas expressas em diferentes ordens de magnitude e unidades distintas. Na qual a normalização dos sinais foi adotada visando melhorar a qualidade numérica do problema de identificação e aumentar a robustez dos modelos estimados. A normalização consiste em reescalar os dados de forma que todas as variáveis apresentem magnitudes comparáveis, evitando que variáveis com valores absolutos elevados dominem o processo de estimação dos parâmetros do modelo.

Em sistemas industriais multivariáveis, como plantas de captura de dióxido de carbono (CO₂), as variáveis operacionais apresentam escalas e unidades significativamente distintas, incluindo vazões, temperaturas, composições químicas e cargas térmicas. Essa heterogeneidade pode comprometer o condicionamento numérico dos métodos de identificação e dos algoritmos de otimização empregados no controle avançado (Ljung, 1999; Qin & Badgwell, 2003).

Neste trabalho, adotou-se a normalização estatística do tipo z-score, amplamente recomendada na literatura de identificação de sistemas e controle preditivo. Esse método consiste na transformação de cada variável $x(k)$ a partir de sua média μ_x e desvio padrão σ_x , conforme:

$$x_{\text{norm}}(k) = \frac{x(k) - \mu_x}{\sigma_x} \quad (4.3)$$

Como resultado, as variáveis normalizadas passam a apresentar média nula e variância unitária. Essa propriedade é particularmente importante, uma vez que os métodos de identificação utilizados neste estudo — tais como modelos ARX, Output Error (OE) e métodos subesaciais (N4SID) — baseiam-se em formulações de mínimos quadrados e decomposições matriciais sensíveis à escala das variáveis (Van Overschee & De Moor, 1996; Ljung, 1999).

Quando os dados não são normalizados, variáveis de maior magnitude numérica tendem a dominar o processo de estimação, independentemente de sua relevância dinâmica real. Isso

pode resultar em modelos mal condicionados, com parâmetros distorcidos e baixa capacidade preditiva. A normalização pelo método z-score melhora o condicionamento das matrizes envolvidas na identificação, reduz a amplificação de erros numéricos e aumenta a robustez do modelo frente a ruídos de medição e perturbações inerentes ao processo (Qin & Badgwell, 2003).

No contexto do controle preditivo de modelos, a normalização desempenha um papel igualmente relevante. O MPC resolve, a cada instante de amostragem, um problema de otimização que minimiza uma função custo quadrática composta por termos associados aos desvios das variáveis controladas e às variações das variáveis manipuladas. Sem normalização, os pesos dessa função custo passam a refletir predominantemente as magnitudes físicas das variáveis, e não sua real importância operacional ou econômica, dificultando a sintonia adequada do controlador (Camacho & Bordons, 2013).

A utilização de variáveis normalizadas garante que os pesos atribuídos na função objetivo do MPC sejam coerentes e comparáveis entre si, além de melhorar o condicionamento do problema de otimização resolvido internamente pelo controlador. Esse aspecto é particularmente importante em estratégias de controle econômico e otimização em tempo real (RTO), nas quais variáveis energéticas, econômicas e ambientais coexistem com escalas bastante distintas (Lucia et al., 2013; Patrón & Ricardez-Sandoval, 2022).

Após a identificação dos modelos e o cálculo das ações de controle no espaço normalizado, realizou-se a desnormalização das variáveis manipuladas antes de sua aplicação ao processo, de acordo com:

$$x(k) = \sigma_x x_{\text{norm}}(k) + \mu_x \quad (4.4)$$

Esse procedimento assegura que as ações de controle respeitem as unidades físicas e os limites operacionais reais da planta simulada. Os parâmetros de normalização (médias e desvios padrão) foram armazenados e utilizados de forma consistente em todas as etapas do estudo, garantindo compatibilidade entre os dados de identificação, os modelos reduzidos e os controladores preditivos.

Dessa forma, a normalização das variáveis não é tratada neste trabalho como uma etapa meramente auxiliar, mas como um elemento fundamental da metodologia de modelagem e controle, contribuindo diretamente para a obtenção de modelos mais robustos, controladores mais estáveis e resultados mais confiáveis em sistemas industriais complexos.

4.4. O MODELO ORIENTADO À PREVISÃO DE SAÍDA (OPOM) COM MENSURAÇÃO DOS DISTÚRBIO

Considerando uma transferência MIMO (múltiplas entradas / múltiplas saídas) com n_u entradas e n_y saídas. Onde considera a função de transferência que relaciona a entrada u_j e d_j à saída y_i e y_d , para o processo com para os distúrbios. A função de transferência no domínio de Laplace, s , é apresentada como (ODLOAK, 2004; PATARO, 2022):

$$G_{i,j}(s) = \frac{y_i}{u_j} = \frac{b_{i,j,0} + b_{i,j,1}s + \dots + b_{i,j,nb}s^{nb}}{1 + a_{i,j,0}s + \dots + a_{i,j,na}s^{na}} \quad (4.5)$$

$$Gd_{i,g}(s) = \frac{y_i}{d_g} = \frac{b_{i,g,0} + b_{i,g,1}s + \dots + b_{i,g,np}s^{np}}{1 + a_{i,j,0}s + \dots + a_{i,j,na}s^{na}} \quad (4.6)$$

Já para os distúrbios de modo semelhante:

$$s_{i,j}(t) = \mathcal{L}^{-1} \left[\frac{b_{i,j,0} + b_{i,j,1}s + \dots + b_{i,j,nb}s^{nb}}{s(s - p_{i,j,1})(s - p_{i,j,2})(s - p_{i,j,na})} \right]$$

$$s_{i,g}(t) = \mathcal{L}^{-1} \left[\frac{b_{i,g,0} + b_{i,g,1}s + \dots + b_{i,g,np}s^{np}}{s(s - p_{di,j,1})(s - p_{i,j,2})(s - p_{i,j,nc})} \right]$$

Onde $\{na, nb \in \mathbb{N} \mid nb < na \text{ e } nc, np \in \mathbb{N} \mid np < nc\}$, e sua etapa correspondente resposta na etapa de tempo k , para um período de amostragem T , é dada por (ODLOAK, 2004; PATARO, 2022):

$$S_{i,j}(k) = d_{i,j}^0 + \sum_{l=1}^{na} [d_{i,j,l}^d] e^{p_{i,j,l}kT} \quad (4.7)$$

$$S_{i,g}(k) = d_{i,g}^{0,d} + \sum_{l=1}^{nc} [d_{i,g,l}^{d,d}] e^{p_{di,g,l}kT} \quad (4.8)$$

Com base de Eq. (3.7), segundo (Martins and Odloak, 2016; PATARO, 2022), o modelo de espaço de estado equivalente para a forma incrementadas entradas e perturbações medidas é expressa em Eqs. (3.9) e (3.10).

$$\underline{x} = \begin{bmatrix} x^s(k+1) \\ x^d(k+1) \\ x_d(k+1) \end{bmatrix} = \begin{bmatrix} I_{ny} & 0 & 0 \\ 0 & F & 0 \\ 0 & 0 & F_d \end{bmatrix} \begin{bmatrix} x^s(k) \\ x^d(k) \\ x_d(k) \end{bmatrix} + \begin{bmatrix} D^0 \\ D^d FN \\ 0 \end{bmatrix} \Delta u(k) + \begin{bmatrix} D_d^0 \\ 0 \\ D_d^d F_d N_d \end{bmatrix} \Delta d(k) \quad (4.9)$$

$$x^s(k+1) = x^s(k) + D^0 \Delta u(k) + D_d^0 \Delta d(k)$$

$$x^d(k+1) = Fx^d(k) + D^d FN \Delta u(k)$$

$$\begin{aligned}
x_d(k+1) &= F_d x_d(k) + D_d^d F_d N_d \Delta d(k) \\
y(k) &= [I_{ny} \quad \Psi \quad \Psi_d] \begin{bmatrix} x^s(k) \\ x^d(k) \\ x_d(k) \end{bmatrix}
\end{aligned} \tag{4.10}$$

Sendo

$$\begin{aligned}
x^s &= [x_1 \dots x_{ny}]^T, x^s \in \mathbb{R}^{ny} \\
x^d &= [x_{ny+1} \dots x_{ny+nd}]^T, x^d \in \mathbb{C}^{nd} \\
nd &= nunany \\
ndw &= nwnany \\
D^0 &\triangleq \begin{bmatrix} d_{1,1}^0 & \dots & d_{1,nu}^0 \\ \vdots & \ddots & \vdots \\ d_{ny,1}^0 & \dots & d_{ny,nu}^0 \end{bmatrix}, D^0 \in \mathbb{R}^{ny \times nu} \\
D_d^0 &\triangleq \begin{bmatrix} d_{1,1}^{0,d} & \dots & d_{1,nw}^0 \\ \vdots & \ddots & \vdots \\ d_{ny,1}^{0,d} & \dots & d_{ny,nw}^{0,d} \end{bmatrix}, D_d^0 \in \mathbb{R}^{ny \times nw} \\
D^d &\triangleq \text{diag}(d_{1,1,1}^d \dots d_{1,1,na}^d \dots d_{1,2,1}^d \dots d_{1,2,na}^d \dots \\
&\quad d_{2,1,1}^d \dots d_{2,1,na}^d \dots d_{ny,1,1}^d \dots d_{ny,1,na}^d \dots d_{ny,nu,1}^d \dots d_{ny,nu,na}^d) \\
D^d &\in \mathbb{C}^{nd \times nd} \\
F &\triangleq \text{diag}(e^{p_{1,1,1}KT} \dots e^{p_{1,1,na}KT} \dots e^{p_{1,nu,1}KT} \dots e^{p_{1,nu,na}KT} \dots \\
&\quad e^{p_{ny,1,1}KT} \dots e^{p_{ny,1,na}KT} \dots e^{p_{ny,nu,1}KT} \dots e^{p_{ny,nu,na}KT})
\end{aligned}$$

$F \in \mathbb{C}^{nd \times nd}$ Matriz dos componentes dinâmicos do sistema

$$\begin{aligned}
F_d &\triangleq \text{diag}(e^{pd_{1,1,1}KT} \dots e^{pd_{1,1,na}KT} \dots e^{pd_{1,nw,1}KT} \dots e^{pd_{1,nw,na}KT} \dots \\
&\quad e^{pd_{ny,1,1}KT} \dots e^{pd_{ny,1,na}KT} \dots e^{pd_{ny,nu,1}KT} \dots e^{pd_{ny,nu,na}KT})
\end{aligned}$$

$F_d \in \mathbb{C}^{ndw \times ndw}$ Matriz dos componentes dinâmicos do sistema par os distúrbios

$$\begin{aligned}
\Psi &= \begin{bmatrix} \phi & \dots & 0 \\ \vdots & \ddots & \vdots \\ 0 & \dots & \phi \end{bmatrix}, \Psi \in \mathbb{R}^{ny \times nd} \\
\Psi_d &= \begin{bmatrix} \phi & \dots & 0 \\ \vdots & \ddots & \vdots \\ 0 & \dots & \phi \end{bmatrix}, \Psi_d \in \mathbb{R}^{ny \times ndw}
\end{aligned}$$

$$N = \begin{bmatrix} j_1 \\ \dots \\ j_{ny} \end{bmatrix}, N \in \mathbb{R}^{ny \times nd}$$

$$j_i \triangleq \begin{bmatrix} 1 & 0 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 1 & 0 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & 1 \\ \vdots & \vdots & \dots & \vdots \\ 0 & 0 & \dots & 1 \end{bmatrix}, j_i \in \mathbb{R}^{nuna \times nu}$$

$$N_d = \begin{bmatrix} j_1 \\ \dots \\ j_{ny} \end{bmatrix}, N \in \mathbb{R}^{ny \times ndw}$$

$$j_i \triangleq \begin{bmatrix} 1 & 0 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 1 & 0 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & 1 \\ \vdots & \vdots & \dots & \vdots \\ 0 & 0 & \dots & 1 \end{bmatrix}, j_i \in \mathbb{R}^{nwna \times nw}$$

$$\phi = [1 \dots 1], \phi \in \mathbb{R}^{nu \times na}$$

$$\phi_d = [1 \dots 1], \phi_d \in \mathbb{R}^{nw \times na}$$

4.5 CONTROLADOR PREDITIVO DE MODELO LINEAR AVANÇADO RESTRITO (CLMPC)

Neste trabalho, o primeiro controlador implementado é um Controlador Preditivo de Modelo Linear Restrito (CLMPC) formulado em espaço de estados, com horizonte finito de predição e controle. O modelo utilizado pelo controlador é obtido a partir da identificação de modelos lineares do processo, originalmente representados por funções de transferência e posteriormente convertidos para uma representação em espaço de estados. O problema pode ser assim formulado como um problema de programação quadrática (Odloak & Kwong, 2019; Bhattacharyya et al., 2016; e He et al., 2018) sujeito a restrições Eq. (4.12), (4.13) e (4.14).

$$\min_{\Delta u} J = \frac{1}{2} \Delta u^T H \Delta u + c^T \Delta u \quad (4.11)$$

subject to:

$$u_{min} \leq u \leq u_{max} \quad (4.12)$$

$$-\Delta u_{max} \leq \Delta u \leq \Delta u_{max} \quad (4.13)$$

$$y_{min} \leq y \leq y_{max} \quad (4.14)$$

$$H = (A^T W^T W A + R) \quad (4.15)$$

$$c^T = e^T W^T W A \Delta u \quad (4.16)$$

Na Eq. (3.15) e (3.16) os termos H e c representam a matriz hessiana (geralmente fixa) e o vetor gradiente, respectivamente. Este problema quadrático foi resolvido de forma eficiente por sub-rotina numérica baseada em gradientes conjugados com o software Matlab-R2022a®

(Camacho e Bordons 1998; Fletcher 1991).

4.6 CONTROLADOR IHMPC

Controladores MPC lineares, possuem estrutura relativamente simples e já foram estudados para plantas de captura pós-combustão (PCC) por Bhattacharyya et al. (2016) e Zang et al. (2018), normalmente considerando horizontes finitos de predição. Apesar de amplamente discutido na literatura, suas aplicações industriais ainda são limitadas (Martin et al., 2019; Forbes et al., 2015; Lee, 2011). Exemplos incluem o uso em uma Unidade de Destilação de Bruto (CDU) de refinaria (Martins et al., 2019) e a proposta de Pataro et al. (2022) para um IHMPC nominalmente estável em malha fechada com ação implícita de *feedforward* (IHMPCFF) para sistemas estáveis com atraso. A principal vantagem do IHMPC em relação ao MPC convencional é sua estabilidade nominal em malha fechada, ou seja, se o processo for perfeitamente representado pelo modelo linear do controlador, a estabilidade é garantida independentemente dos parâmetros de ajuste (Odloak, 2004). Isso não elimina a necessidade de *tuning*, mas tende a simplificá-lo ou permitir ajustes mais agressivos. Embora modelos perfeitos sejam raros na prática, essa característica torna o IHMPC atrativo para aplicações industriais (Qin e Badgwell, 2003).

4.6.1 Formulação do IHMPCFF

O MPC de horizonte infinito é baseado na seguinte função custo:

$$V_k = \sum_{j=0}^{\infty} [e(k+j) - \delta_k]^T Q [e(k+j) - \delta_k^s] + \sum_{j=0}^{m-1} \Delta u(k+j)^T R \Delta u(k+j) + \delta_k^T S \delta_k \quad (4.17)$$

Sendo,

$e(k+j) = y(k+j) - y^{sp}$ é o erro de previsão em relação à saída de referência. $Q \in \mathbb{R}^{ny}$ and $R \in \mathbb{R}^{ny}$ são as matrizes de ponderação das variáveis de entrada e saída e $\delta_k \in \mathbb{R}^{ny}$ o vetor de variáveis de folga que permitem um maior grau de liberdade para a solução do problema dentro da região viável U , S é a matriz de pesos, positiva e definida.

A função objetivo proposta ainda não está limitada devido à presença de estados integradores artificiais originados da forma proposta dos insumos incrementais. Além disso, para o IHMPC expresso com ação feedforward implícita, assume-se que tanto as entradas de controle quanto os distúrbios são constantes além o horizonte de controle, ou seja, $\Delta u(k+j) = 0$ e $\Delta d(k+j) = 0$ para $j \geq m$. Portanto, para limitar a função custo, propõe-se uma folga restrição

de igualdade terminal para os estados de integração artificial, que e:

$$e^s(k) - \delta_k + \tilde{D}^0 \Delta u + \tilde{D}_d^0 \Delta d = 0 \quad (4.18)$$

Portanto, seguindo a restrição terminal na Eq. (3.16) o problema de otimização é reduzido a:

$$\begin{aligned} V_k = & \sum_{j=0}^m [e(k+j) - \delta_k]^T Q [e(k+j) - \delta_k^s] + x^d(k+j)^T \bar{Q} x^d(k+j) \\ & + \sum_{j=0}^{m-1} \Delta u(k+j)^T R \Delta u(k+j) + \delta_k^T S \delta_k + x_d(k+j)^T \bar{Q}_{di} x_d(k+j) \end{aligned} \quad (4.19)$$

em que a matriz de pesos terminais $\bar{Q}$ e $\bar{Q}_{di}$ são a solução da equação de Lyapunov, mostrada a seguir:

$$\bar{Q} - F^T \bar{Q} F = F^T \Psi^T Q \Psi F \quad (4.20)$$

$$\bar{Q}_{di} - F^{diT} \bar{Q}_{di} F^{di} = F^{diT} \Psi^{diT} Q \Psi^{di} F^{di} \quad (4.21)$$

Para obter uma expressão mais simples para o objetivo de controle acima, Eqs. 4.20 e 3.21 podem ser usados para avaliar o estado e a saída em instantes de amostragem futuros como segue:

Temos que a predição com relação a componente estática e da seguinte forma:

$$\begin{aligned} x^s(k+1) &= x^s(k) + D^0 \Delta u(k) + D_d^0 \Delta d(k) \\ x^s(k+2) &= x^s(k+1) + D^0 \Delta u(k+1) + D_d^0 \Delta d(k+1) \\ &= x^s(k) + D^0 \Delta u(k) + D^0 \Delta u(k+1) + D_d^0 \Delta d(k) + D_d^0 \Delta d(k+1) \\ x^s(k+3) &= x^s(k+2) + D^0 \Delta u(k+2) + D_d^0 \Delta d(k+2) \\ &= x^s(k) + D^0 \Delta u(k) + D^0 \Delta u(k+1) + D^0 \Delta u(k+2) + D_d^0 \Delta d(k) \\ &\quad + D_d^0 \Delta d(k+1) + D_d^0 \Delta d(k+2) \end{aligned}$$

Logo, para um instante $k+j$

$$\begin{aligned} x^s(k+j) &= x^s(k) + D^0 \Delta u(k) + \dots + D^0 \Delta u(k+j-1) + D_d^0 \Delta d(k) + \dots \\ &\quad + D_d^0 \Delta d(k+j-1) \end{aligned}$$

Na forma matricial temos:

$$\begin{aligned}
x^s(k+j) &= x^s(k) + [D^0 \ D^0 \ D^0 \ \dots \ D^0] \begin{bmatrix} \Delta u(k) \\ \Delta u(k+1) \\ \Delta u(k+2) \\ \vdots \\ \Delta u(k+m-1) \end{bmatrix} \\
&\quad + [D_d^0 \ D_d^0 \ D_d^0 \ \dots \ D_d^0] \begin{bmatrix} \Delta d(k) \\ \Delta d(k+1) \\ \Delta d(k+2) \\ \vdots \\ \Delta d(k+m-1) \end{bmatrix} \\
x^s &= Ix^s(k) + D_m^0 \Delta u + D_{dm}^0 \Delta d
\end{aligned} \tag{4.22}$$

Já para a componente dinâmica temos:

$$\begin{aligned}
x^d(k+1) &= Fx^d(k) + D^d FN \Delta u(k) \\
x^d(k+2) &= Fx^d(k+1) + D^d FN \Delta u(k+1) \\
&= F[Fx^d(k) + D^d FN \Delta u(k)] + D^d FN \Delta u(k+1) \\
x^d(k+2) &= F^2 x^d(k) + D^d F^2 N \Delta u(k) + D^d FN \Delta u(k+1)
\end{aligned}$$

Logo, para um instante $k+j$

$$x^d(k+j) = F^j x^d(k) + D^d F^j N \Delta u(k) + D^d F^{j-1} N \Delta u(k+1) + \dots + D^d FN \Delta u(k+m-1)$$

De modo análogo,

$$x^d = F_x x^d(k) + F_u \Delta u \tag{4.23}$$

Sendo:

$$\begin{aligned}
x^d &= [x^d(k+1) \ x^d(k+2) \ \dots \ x^d(k+j)]^T \\
F_x &= [F \ F^2 \ \dots \ F^j]^T \\
F_u &= \begin{bmatrix} F & 0 & 0 & \dots & 0 \\ F^2 & F & 0 & \dots & 0 \\ F^3 & F^2 & F & \dots & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ F^j & F^{j-1} & F^{j-2} & \dots & F \end{bmatrix} \begin{bmatrix} D^d N & 0 & 0 & \dots & 0 \\ 0 & D^d N & 0 & \dots & 0 \\ 0 & 0 & D^d N & \dots & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & 0 & \dots & D^d N \end{bmatrix}
\end{aligned}$$

Já com relação a contribuição dos distúrbios temos:

$$\begin{aligned}
x_d(k+1) &= F_d x_d(k) + D_d^d F_d N_d \Delta d(k) \\
x_d(k+2) &= F_d x_d(k+1) + D_d^d F_d N_d \Delta d(k+1) \\
&= F[F_d x_d(k) + D_d^d F_d N_d \Delta d(k)] + D_d^d F_d N_d \Delta d(k+1) \\
x_d(k+2) &= F_d^2 x_d(k) + D_d^d F_d^2 N_d \Delta d(k) + D_d^d F_d N_d \Delta d(k+1)
\end{aligned}$$

Logo, para um instante $k+j$

$$\begin{aligned}
x_d(k+j) &= F_d^j x_d(k) + D_d^d F_d^j N_d \Delta u(k) + D_d^d F_d^{j-1} N_d \Delta d(k+1) + \dots \\
&\quad + D_d^d F_d N_d \Delta d(k+m-1)
\end{aligned}$$

De modo análogo,

$$x_d = F_{dx}x_d(k) + F_{du}\Delta d \quad (4.24)$$

Sendo:

$$x_d = [x_d(k+1) \ x_d(k+2) \ \dots \ x_d(k+j)]^T$$

$$F_{dx} = [F_d \ F_d^2 \ \dots \ F_d^j]^T$$

$$F_{du} = \begin{bmatrix} F_d & 0 & 0 & \dots & 0 \\ F_d^2 & F_d & 0 & \dots & 0 \\ F_d^3 & F_d^2 & F_d & \dots & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ F_d^j & F_d^{j-1} & F_d^{j-2} & \dots & F_d \end{bmatrix} \begin{bmatrix} D_d^d N_d & 0 & 0 & \dots & 0 \\ 0 & D_d^d N_d & 0 & \dots & 0 \\ 0 & 0 & D_d^d N_d & \dots & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & 0 & \dots & D_d^d N_d \end{bmatrix}$$

A expressão do erro tem a seguinte modificação:

$$e(k+j) = x^s(k+j) - y^{sp} + \Psi x^d(k+j) + \Psi_d x_d(k+j)$$

$$e(k+j) = Ix^s(k) + D_m^0 \Delta u + D_{dm}^0 \Delta d - y^{sp} + \Psi(F_x x^d(k) + F_u \Delta u)$$

$$+ \Psi_d(F_{dx} x_d(k) + F_{du} \Delta d)$$

Temos que:

$$e^s(k) = Ix^s(k) - y^{sp}$$

$$e(k+j) = e^s(k) + D_m^0 \Delta u + D_{dm}^0 \Delta d - y^{sp} + \Psi(F_x x^d(k) + F_u \Delta u)$$

$$+ \Psi_d(F_{dx} x_d(k) + F_{du} \Delta d)$$

Com as variáveis definidas acima, o objetivo de controle representado na Eq. 4.24 pode ser escrito como:

$$V_{k2} = [\Delta u_k^T \ \delta_k^T] H \begin{bmatrix} \Delta u_k \\ \delta_k \end{bmatrix} + 2c_f^T [\Delta u_k \ \delta_k] \quad (4.25)$$

Onde

$$H = \begin{bmatrix} (D_m^0 + \Psi_1 F_u)^T Q_1 (D_m^0 + \Psi_1 F_u) + F_u^T Q_2 F_u + R_1 & -(D_m^0 + \Psi_1 F_u) Q_1 \bar{I} \\ -\bar{I}^T Q_1 (D_m^0 + \Psi_1 F_u) & S + \bar{I}^T Q_1 \bar{I} + Q_1 \end{bmatrix} \quad (4.26)$$

$$c_{ff} = (D_m^0 + \Psi_1 F_u)^T Q_1 [\bar{I} e^s(k) + \Psi_1 F_x x^d(k)] + (D_m^0 + \Psi_1 F_u)^T Q_1 (D_{dm}^0 + \Psi_d F_{du}) \Delta d$$

$$+ (D_{dm}^0 + \Psi_{d1} F_{du})^T Q_1 [\Psi_{d1} F_{dx} x_d(k)] + F_u^T Q_2 [F_x x^d(k)]$$

$$c_f = \begin{bmatrix} c_{ff} \\ -\bar{I}^T Q_1 [\bar{I} e^s(k) + \Psi_1 F_x x^d(k)] + Q e(k) \end{bmatrix} \quad (4.27)$$

$$\bar{I} = \begin{bmatrix} I_{ny} \\ \vdots \\ I_{ny} \end{bmatrix}, \bar{I} \in \mathbb{R}^{mny \times ny}$$

$$Q_1 = \text{diag} \left[\overbrace{Q \dots Q}^m \right] \quad Q_2 = \text{diag} \left[\overbrace{0 \dots 0}^m \ \bar{Q} \right]$$

$$R_1 = \text{diag} \left[\overbrace{R \dots R}^m \right] \quad \Psi_1 = \text{diag} \left[\overbrace{\Psi \dots \Psi}^m \right] \quad \Psi_{d1} = \text{diag} \left[\overbrace{\Psi_d \dots \Psi_d}^m \right]$$

Finalmente, o problema de otimização de controle da extensão MPC de horizonte infinito (IHMPCFF) pode ser formulado como:

$$\min_{\Delta u_k, \delta_k} V_k = [\Delta u_k^T \ \delta_k^T] H \begin{bmatrix} \Delta u_k \\ \delta_k \end{bmatrix} + 2c_f^T [\Delta u_k \ \delta_k] + c$$

Sujeito a:

$$\Delta u(k+j) \in U \quad j \geq 0$$

$$e^s(k) - \delta_k + \tilde{D}^0 \Delta u + \tilde{D}_d^0 \Delta d = 0$$

$$U = \left\{ \Delta u(k+j) \left| \begin{array}{l} -\Delta u_{max} \leq \Delta u(k+j) \leq \Delta u_{max} \\ \Delta u(k+j) = 0 \quad j \geq m \\ u_{min} \leq u(k-1) + \sum_{i=0}^j \Delta u(k+i) \leq u_{max} \quad j = 0, 1, \dots, m-1 \end{array} \right. \right\}$$

4.7 OBSERVADOR DE ESTADO LINEARES

Todos os controladores propostos neste trabalho assumem que o estado é conhecido no passo de tempo k e pode ser usado para o cálculo das previsões de saída. Este estado é medido, como no modelo de realinhamento, ou deve ser estimado a partir das medições dinâmicas da planta, como no caso do modelo OPOM. Como o modelo considerado no controlador é linear, ele sempre será diferente do modelo não linear real do sistema e, consequentemente, a estimativa do estado não será exata.

Ao considerar um observador de estados, um dos principais aspectos a ser levado em consideração é que o observador deve garantir a convergência assintótica do erro entre o estado estimado e o estado real para zero. No entanto, outros requisitos podem ser adicionados, como um desempenho ótimo para o ruído esperado da planta (Ljung, 1999; Simon, 2006).

Aqui, o filtro de Kalman será incluído nas estratégias de controle baseadas no modelo OPOM. Neste caso, o filtro deve estimar o estado completo x , usando uma relação de feedback do erro de estimativa como segue:

$$\hat{x}(k+1) = A\hat{x}(k) + B\Delta u(k) + B_d\Delta d(k) + K_F (y - C\hat{x}(k)) \quad (4.28)$$

Para uma implementação prática deste filtro, as covariâncias de ruído devem ser conhecidas ou consideradas como parâmetros de ajuste do filtro. Aqui, esses parâmetros são considerados são:

$$V = 0.001xI_{ny} \in \mathbb{R}^{ny \times ny}$$

$$W = 10xI_{ny} \in \mathbb{R}^{ny \times ny}$$

Então, o ganho K_F do ganho do filtro de Kalman pode ser calculado como:

$$P = APA^T + W - (APC^T)(CPC^T + V)^{-1}(CPA^T) \quad (4.29)$$

$$K_F = (APC^T)(CPC^T + V)^{-1} \quad (4.30)$$

4.8 INTEGRAÇÃO RTO E MPC.

Plantas de captura pós-combustão (PCC) estão sujeitas a perturbações frequentes que afetam diretamente seu desempenho operacional e econômico. Condições anteriormente ótimas podem se tornar subótimas, tornando necessário atualizar periodicamente os pontos de ajuste (*setpoints*).

Por exemplo, um sistema PCC projetado para operar com elevada taxa de remoção de CO₂ pode sofrer uma queda na fração de CO₂ nos gases de combustão. Nesse cenário, a redução do ponto de ajuste de remoção não comprometeria o atendimento às metas ambientais e, ao mesmo tempo, permitiria reduzir o consumo de solvente, água e energia, diminuindo os custos operacionais. Considerando que o impacto econômico do PCC sobre a planta a montante é um dos principais obstáculos à sua adoção, estratégias de operação economicamente otimizadas são essenciais para viabilizar sua implementação em larga escala.

A integração proposta segue uma arquitetura de duas camadas (Figura 4.5):


- Camada de Controle Dinâmico (IHMPCCFF/CLMPC) – Opera em horizonte curto, recebendo pontos de ajuste do RTO e atuando sobre as variáveis manipuladas para regular as variáveis controladas. As ações de controle são aplicadas à planta, e as medições resultantes passam pelo Filtro de Kalman, que fornece estimativas atualizadas do estado do processo.
- Camada de Otimização Econômica (RTO) – Atua em horizonte mais longo, sendo acionada quando o processo atinge novo regime permanente. Utiliza medições filtradas para recalcular pontos de ajuste economicamente ótimos ($Y_{sp}=Y_{RTO}$), considerando custos energéticos, receita de venda de CO₂ e custo social do carbono.

O funcionamento cíclico é o seguinte:

1. O IHMPCCFF/CLMPC mantém as variáveis controladas próximas aos pontos definidos pelo RTO, mesmo diante de perturbações.
2. Quando ocorre uma variação significativa e o sistema estabiliza em novo regime permanente, o RTO é acionado para atualizar os *setpoints*.
3. O ciclo se repete, garantindo operação continuamente ajustada ao ponto ótimo econômico.

Dessa forma, a integração RTO/IHMPCCFF/CLMPC combina otimização de médio-longo prazo com controle dinâmico de curto prazo, resultando em operação mais robusta e eficiente.

Figura 4. 5 - Esquema proposto para plantas de PCC



Fonte: o autor

4.9 FORMULAÇÃO RTO

A formulação de RTO utilizada para fornecer pontos de ajuste atualizados para os controladores da planta de PCC é uma forma simplificada da fórmula utilizada segundo (Patron,2022):

Formulação da função objetivo do RTO:

$$\min_j P_{CO_2} \dot{m}_{CO_2}^{vent} + P_{sales} \zeta \dot{m}_{CO_2}^{cap} + \sum_j P_{energy,j} Q_{energy,j}$$

Sj.

$$\begin{aligned} Y &= G'u + G_d'd \\ Y^l &\leq Y \leq Y^h \\ u^l &\leq u \leq u^h \end{aligned}$$

Na qual a função objetivo proposta considera três componentes principais. O primeiro é a receita obtida com a venda do CO₂ capturado, calculada pelo produto entre o preço de comercialização, a taxa de captura e um fator de eficiência $\zeta \in [0,1]$ que representa a fração efetivamente vendida. Por se tratar de receita, este termo assume sinal negativo na função, reduzindo o custo total. O segundo componente é o custo social do carbono (CSC), que inclui tanto o valor de mercado das emissões quanto as externalidades negativas não internalizadas, como impactos à saúde e ao meio ambiente. Esse termo é obtido pelo produto entre o preço da emissão P_{CO_2} e a taxa de emissão pelo gás de ventilação $\dot{m}_{CO_2}^{cap}$, funcionando como uma

penalidade econômica que incentiva a redução das emissões. O terceiro termo corresponde ao custo energético, que abrange o consumo das unidades intensivas em energia j (por exemplo, refervedores, sopradores, bombas e pré-aquecedores) e é calculado pelo produto entre o preço unitário $P_{energy,j}$ e a demanda de energia $Q_{energy,j}$. Assim, a função objetivo integra simultaneamente a maximização da receita de venda de CO₂ e a minimização dos custos relacionados às emissões e ao consumo energético, orientando a operação para maior eficiência econômica.

Considerando os termos da função objetivo pode-se fazer a seguinte mudança na função objetivo, onde primeiramente temos que:

$$\dot{m}_{CO_2}^{cap} = \dot{m}_{CO_2}^{fuegas} - \dot{m}_{CO_2}^{vent} \quad (4.31)$$

Sendo

$$\begin{aligned} \%CC &= \frac{(\dot{m}_{CO_2}^{fuegas} - \dot{m}_{CO_2}^{vent})}{\dot{m}_{CO_2}^{fuegas}} * 100 \\ \dot{m}_{CO_2}^{vent} &= \dot{m}_{CO_2}^{fuegas} - \frac{\dot{m}_{CO_2}^{fuegas} \%CC}{100} \\ \dot{m}_{CO_2}^{vent} &= \dot{m}_{CO_2}^{fuegas} \left(1 - \frac{\%CC}{100}\right) \\ \dot{m}_{CO_2}^{fuegas} &= y_{CO_2} N_{fuegas} MM_{CO_2} \\ \dot{m}_{CO_2}^{vent} &= y_{CO_2} N_{fuegas} MM_{CO_2} \left(1 - \frac{\%CC}{100}\right) \end{aligned} \quad (4.32)$$

Dessa forma,

$$\begin{aligned} \min_j P_{CO_2}^{emit} &\left(y_{CO_2} N_{fuegas} MM_{CO_2} \left(1 - \frac{\%CC}{100}\right) \right) \\ &+ P_{sales} \left(y_{CO_2} N_{fuegas} MM_{CO_2} - y_{CO_2} N_{fuegas} MM_{CO_2} \left(1 - \frac{\%CC}{100}\right) \right) \\ &+ P_{energy} (Q_{reb,D-101} + Q_{reb,D-102}) \end{aligned}$$

Rearranjando temos o seguinte problema de otimização:

$$\begin{aligned} \min_j P_{CO_2}^{emit} &\left(y_{CO_2} N_{fuegas} MM_{CO_2} \left(1 - \frac{\%CC}{100}\right) \right) \\ &+ P_{sales} \left(y_{CO_2} N_{fuegas} MM_{CO_2} \left(1 - \left(1 - \frac{\%CC}{100}\right)\right) \right) \\ &+ P_{energy} (Q_{reb,D-101} + Q_{reb,D-102}) \end{aligned}$$

Sj.

$$\begin{aligned} Y &= G'u + G_d'd \\ Y^l &\leq Y \leq Y^h \\ u^l &\leq u \leq u^h \end{aligned}$$



5 RESULTADOS E DISCUSSÕES

5.1 SIMULAÇÃO E IDENTIFICAÇÃO DO PROCESSO


O comportamento dinâmico observado nas variáveis do processo, como a taxa de captura de CO₂ e as temperaturas nas correntes do absorvedor e do stripper, pode ser explicado pela interação de múltiplos efeitos físico-químicos que atuam em diferentes escalas de tempo sobre a resposta do sistema. A Figura 5.1 apresenta as respostas do sistema a perturbações em forma de degrau de +10% na composição do flegas e lean e +5% na vazão de *fluegas* respectivamente, evidenciando as diferenças de dinâmica e de sensibilidade entre as variáveis controladas.

Figura 5. 1 - Resposta ao degrau para saídas do processo: a) +10% na composição do flegas; b) +10% na vazão de lean; c) +5% vazão de *fluegas*

a)



b)



A análise de sensibilidade dinâmica realizada no Aspen Dynamics® evidencia o comportamento do processo de absorção de CO₂ frente a diferentes perturbações operacionais. O aumento da vazão de fluegas resulta em redução imediata na taxa de captura, devido ao menor tempo de residência do gás e à diminuição do calor liberado por mol de CO₂ absorvido, caracterizando uma resposta rápida e fortemente acoplada ao balanço de massa e energia. Por outro lado, o aumento da vazão de solvente pobre intensifica a capacidade de absorção e eleva significativamente a temperatura do sistema, em função do maior fluxo de solvente que precisa ser aquecido no reboiler, apresentando resposta mais lenta (3–4 h). Já a elevação da fração molar de CO₂ na corrente de entrada reforça a driving force de absorção, aumentando a taxa de captura com resposta rápida e impacto térmico reduzido.

Esses resultados demonstram que as variáveis manipuladas apresentam dinâmicas distintas e devem ser tratadas de forma diferenciada na configuração de sinais PRBS para identificação do modelo multivariável. Variáveis de resposta rápida (vazão de fluegas e composição do gás) exigem excitações com tempos de bit curtos, enquanto variáveis de resposta mais lenta, como a vazão de solvente pobre, requerem tempos de bit mais longos. Dessa forma, assegura-se que a identificação capture adequadamente a dinâmica real do processo, possibilitando o desenvolvimento de controladores preditivos robustos e economicamente eficientes.

Os sinais de entrada aleatórios foram usados para vazão de gás de combustão, composição de CO₂ no gás de combustão, Carga térmica das duas torres de Stripper e vazão de solvente pobre são mostrados nas Figuras 4.2. As magnitudes desses sinais aleatórios são selecionadas para representar pequenas variações em torno do ponto de projeto na operação do processo de captura de CO₂. O processo de identificação é realizado utilizando a caixa de ferramentas de Identificação de Sistemas do Matlab. Os modelos de Taxa de captura de CO₂ e das temperaturas do refeedor das strippers são identificados como de primeira ordem (Equações 5.1 a 5.3) foram gerados 20 mil dados separados 70% identificação e 30% validações. A Figura 4.3 mostra as comparações entre as saídas da simulação dinâmica e os modelos identificados. na vazão de solvente pobre (u_1), vazão de *flue gas* (u_2), composição de gás de CO₂ no *flue gas* (u_3), Carga térmica do refeedor da coluna D-101 (u_4) e na Carga térmica do refeedor da coluna D-102 (u_5). A % CC (y_1), T_{REB-D101} (y_2) e T_{REB-D102} (y_3) foram identificados como modelos de primeira ordem, conforme as equações (5.1), (5.2) e (5.3).

$$y_1(s) = \frac{1.5778}{s + 41.716}u_1(s) + \frac{45.925}{s + 42.954}u_2(s) + \frac{-33.967}{s + 89.03}u_3(s) + \frac{0.0016648}{s + 0.28824}u_4(s) + \frac{0.0015037}{s + 10.512}u_5(s) \quad (5.1)$$

$$y_2(s) = \frac{-1.6398}{s + 0.30062}u_1(s) + \frac{1.1358}{s + 0.306991}u_2(s) + \frac{0.9467}{s + 0.75175}u_3(s) + \frac{1.6873}{s + 1.6833}u_4(s) + \frac{0.22359}{s + 0.75197}u_5(s) + \frac{0.93609}{s + 0.75148}e^{-0.001s}y_1(s) \quad (5.2)$$

$$\begin{aligned}
y_3(s) = & \frac{-1.7957}{s + 0.60232}u_1(s) + \frac{1.1535}{s + 0.60758}u_2(s) + \frac{1.5538}{s + 0.95028}u_3(s) \\
& + \frac{0.38621}{s + 0.7911}u_4(s) + \frac{1.6785}{s + 1.6262}u_5(s) \\
& + \frac{2.2523}{s + 0.79261}e^{-0.001s}y_1(s)
\end{aligned} \tag{5.3}$$

Variáveis:





- vazão de solvente pobre (u_1);
- vazão de *flue gas* (u_2);
- composição de gás de CO₂ no *flue gas* (u_3);
- Carga térmica do refeedor da coluna D-101(u_4);
- Carga térmica do refeedor da coluna D-102(u_5);
- % CC (y_1)
- T_{REB-D101} (y_2)
- T_{REB-D102} (y_3)

Tabela 5. 1 - Estado estacionário e parâmetros do PRBS

Variáveis	Valor De Estado Estacionário	Amplitude Do (Prbs)	Tempo
Flue gás (Kmol/s)	20,1	±3%	
Lean Solve (Kmol/s)	110,1	±5%	
Y _{CO2}	0,163	±5%	
Q _{reb-D101} (MW)	5.63	±4%	
Q _{reb-D102} (MW)	5.63	±4%	
%CC	90	-	-
T _{REB-D101}	397	-	-
T _{REB-D102}	398	-	-


Figura 5. 2 - Implementação de sinais aleatórios de vazão de solvente pobre e composição de CO₂ dos gases de combustão, Carga térmica das duas torres de stripper para identificação do


sistema



Fonte: Autor

Figura 5. 3 - Comparação entre o Aspen Plus Dynamics® e os modelos de processo identificados





Fonte: o autor

5.2. ESTRUTURA DE DUAS CAMADAS DA INTEGRAÇÃO RTO/MPC

A integração proposta adota uma arquitetura hierárquica de duas camadas, na qual o RTO ocupa a camada superior e o MPC atua na camada inferior. O RTO, executado em horizonte mais longo, utiliza o modelo do processo e a função objetivo econômica definida na Seção anteriores para determinar pontos de ajuste (setpoints) ótimos para as variáveis controladas, considerando custos de emissão, consumo energético e receita de venda de CO₂. Esses setpoints são então enviados para o MPC, que opera em horizonte de predição curto, garantindo que o processo siga as metas definidas pelo RTO enquanto respeita restrições operacionais e limitações dinâmicas. A tabela 4.2 mostra os parâmetros da função objetivo económica.

Tabela 5. 2 - Preços em termos econômicos, ajustados pela inflação e convertidos para US\$

Termos	Valores
P_{sales}	25 US\$/tCO ₂ capturado
$p_{CO_2}^{emit}$	45 US\$/tCO ₂ emitido
P_{energy}	55 US\$/MWh

5.2.1 Caso Nominal

Os resultados para o CLMPC em comparação com IHMPCFF, são mostrados nesta seção. Além disso, apresentam-se os parâmetros de sintonia adotados para cada controlador

nominal.

5.2.1.1. CLMPC

Os parâmetros de ajuste adotados para testar este controlador são mostrados na Tabela 5.3 como também os valores utilizados como restrições no problema de otimização do controlador na Tabela 5.4.

Tabela 5. 3 - CLMPC- Movimentos máximos de entrada e saídas

Variáveis	Descrição	Δu_{max}	u_{min}	u_{max}	y_{min}	y_{max}
u_1 (kmol/s)	Vazão de solvente pobre	10	60	200	-	-
u_4 (W)	Carga Térmica da coluna de stripper D-101	10^3	$3 \cdot 10^8$	$7 \cdot 10^8$	-	-
u_5 (W)	Carga Térmica da coluna de stripper D-102	10^3	$3 \cdot 10^8$	$7 \cdot 10^8$	-	-
y_1 (%CC)	Taxa de Captura de CO ₂	-	-	-	80	100
y_2 (K)	Temperatura da stripper D-101	-	-	-	300	450
y_3 (K)	Temperatura da stripper D-102	-	-	-	300	450

Tabela 5. 4 - parâmetros de ajuste CLMPC

Tempo de amostragem	$T = 0.01$ h
Horizonte de controle	$m = 6$
Horizonte de predição	$R = 30$
Peso de supressão de entrada	$Q_u = diag ([0.5 \ 1 \ 1])$
Peso de saída controlado	$Q_y = diag ([1 \ 1 \ 1])$

5.2.1.2 IHMPCFF

Os resultados dos experimentos de simulação com o IHMPCFF nominal usando a representação do modelo OPOM são mostrados nas Figuras 5.4 – 5.9. As restrições de entrada são definidas na tabela 5.5. Os parâmetros de ajuste adotados para testar este controlador são mostrados na Tabela 5.6.

Tabela 5. 5 - Movimentos máximos de entrada

Variáveis	Descrição	Δu_{max}	u_{min}	u_{max}
u_1 (kmol/s)	Vazão de solvente pobre	10	60	200

$u_4 (W)$	Carga Térmica da coluna de stripper D-101	10^3	3.10^8	7.10^8
$u_5 (W)$	Carga Térmica da coluna de stripper D-102	10^3	3.10^8	7.10^8

Tabela 5. 6 - parâmetros de ajuste IHMPCFF

Tempo de amostragem	$T = 0.01 \text{ h}$
Horizonte de controle	$m = 1$
Peso de saída controlado	$Q_y = \text{diag} ([1 \ 1 \ 1])$
Otimizando o peso alvo de entrada	$Q_u = \text{diag} ([0.5 \ 1 \ 1])$
Peso das variáveis de folga δ_y	$S_y = 10^{10} \text{diag} ([1 \ 1 \ 1])$

5.2.1.3 Caso Nominal Resultados

A comparação do desempenho nominal dos controladores foi realizada por meio de testes em distintas condições operacionais, permitindo avaliar a eficácia de cada estratégia de controle.

Figura 5.4 Saídas controladas 1º caso




Figura 5. 5 - Entradas Manipuladas 1° caso





Figura 5. 6 - Função econômica 1° caso



A avaliação do desempenho do sistema integrado RTO/MPC foi conduzida considerando três aspectos principais: (i) a resposta das variáveis controladas, (ii) a atuação das variáveis manipuladas e (iii) a evolução da métrica econômica. Para esse fim, foram aplicadas três perturbações sucessivas na fração molar de CO_2 do gás de entrada, consistindo em um aumento de +5% em $t = 0,5$ h, uma redução de -5% em $t = 1,1$ h e um novo aumento de +6% em $t = 1,5$ h. Essas perturbações permitem avaliar a robustez e a capacidade de rejeição de distúrbios das estratégias IHMPC e CLMPC sob diferentes condições operacionais.

A Figura 5.4 apresenta a evolução temporal da taxa de captura de CO_2 (%CC) e das temperaturas dos strippers. Observam-se distintos regimes dinâmicos ao longo da simulação, associados tanto às perturbações impostas na composição do gás de entrada quanto às mudanças de setpoint decorrentes da camada de otimização em tempo real. Após a primeira perturbação (+5% em $t = 0,5$ h), ambas as estratégias ajustam rapidamente suas ações de controle, mantendo a %CC próxima ao valor de referência, com sobre-elevação desprezível e tempo de acomodação reduzido. A segunda perturbação (-5% em $t = 1,1$ h) resulta em uma diminuição temporária da carga de CO_2 no sistema, sendo prontamente compensada pelos controladores, novamente sem oscilações relevantes ou erro estacionário. A terceira perturbação (+6% em $t = 1,5$ h), de maior magnitude, representa o cenário mais severo analisado; ainda assim, tanto o IHMPC quanto o CLMPC preservam o rastreamento da %CC, evidenciando elevada capacidade de rejeição de distúrbios. Em todos os casos, o IHMPCFF apresenta resposta ligeiramente mais suave e monotônica, enquanto o CLMPC exibe pequenas variações transitórias adicionais, típicas de modelos linearizados.

No que se refere às temperaturas dos strippers, observa-se que estas permanecem próximas aos seus respectivos setpoints ao longo de todo o horizonte de simulação, mesmo durante a ocorrência das três perturbações. As variações térmicas observadas são de baixa amplitude e restritas aos instantes imediatamente após a aplicação dos distúrbios, indicando que a regulação da taxa de captura não comprometeu o controle térmico do processo. Novamente, o IHMPCFF apresenta perfis ligeiramente mais suaves, enquanto o CLMPC mantém estabilidade adequada e sem violação de restrições.

A Figura 5.5 apresenta o comportamento das variáveis manipuladas, incluindo a vazão de solvente pobre (Flean) e as cargas térmicas dos refeedores. Após a primeira perturbação positiva na composição de CO_2 ($t = 0,5$ h), observa-se um aumento imediato da vazão de solvente, principal grau de liberdade utilizado para compensar o acréscimo de carga de CO_2 no sistema. Com a aplicação da perturbação negativa em $t = 1,1$ h, ocorre uma redução correspondente de Flean, refletindo a menor necessidade de absorção. A terceira perturbação

(+6% em $t = 1,5$ h) provoca novamente um aumento dessa vazão, sendo esta a resposta mais pronunciada ao longo da simulação. Em todos os casos, o IHMPCFF executa as transições de forma mais suave, com menor variação abrupta entre os níveis de operação, enquanto o CLMPC apresenta pequenas oscilações residuais. As cargas térmicas dos refeedores, por sua vez, permanecem praticamente constantes, sofrendo apenas ajustes marginais, o que indica que a estratégia de controle priorizou a atuação via vazão de solvente para mitigar os efeitos das perturbações, minimizando impactos sobre o consumo de vapor.

A Figura 5.6 apresenta a evolução da função econômica acumulada ao longo do horizonte de simulação. Antes da aplicação das perturbações, a métrica econômica mantém-se em regime estável. A perturbação positiva aplicada em $t = 0,5$ h resulta em um aumento temporário do custo, associado ao maior consumo de solvente e à necessidade de manter a eficiência de captura diante do aumento da carga de CO₂. A perturbação negativa em $t = 1,1$ h promove uma redução momentânea da taxa de crescimento do custo, refletindo a menor exigência operacional. Já a perturbação mais severa (+6% em $t = 1,5$ h) provoca novo incremento no custo acumulado, evidenciando o esforço adicional requerido para manter o desempenho do processo. Apesar dessas variações, as curvas associadas ao IHMPCFF e ao CLMPC permanecem praticamente sobrepostas ao longo de toda a simulação, confirmando que ambas as estratégias apresentam desempenho econômico equivalente, mesmo sob múltiplas perturbações consecutivas.

Figura 5. 7 - Saídas controladas 2º caso




Figura 5. 8 - Entradas Manipuladas 2º caso





Figura 5. 9 - Função econômica 2º caso



No segundo cenário avaliado, foram introduzidas duas perturbações sucessivas na vazão do gás de entrada, correspondentes a um aumento de +5% em $t = 0,5$ h e a uma redução de -5% em $t = 1,1$ h, com o objetivo de analisar a robustez e a capacidade de rejeição de distúrbios dos controladores IHMPCFF e CLMPC. Essas variações representam condições operacionais realistas, associadas a flutuações de carga na unidade geradora, afetando diretamente a quantidade de CO_2 alimentada à planta e, consequentemente, as exigências de captura e consumo energético.

A resposta das variáveis controladas, apresentada na Figura 5.7, evidencia diferenças sutis, porém consistentes, entre as duas estratégias. Até a ocorrência da primeira perturbação, ambos os controladores mantêm a taxa de captura de CO_2 (%CC) e as temperaturas dos refeedores próximas aos seus respectivos setpoints. Após o aumento de vazão em $t = 0,5$ h, observa-se que o IHMPCFF rejeita o distúrbio de forma progressiva, preservando a %CC praticamente inalterada e evitando sobre-elevações perceptíveis. Em contraste, o CLMPC apresenta pequenas oscilações transitórias, especialmente mais visíveis na resposta térmica. A perturbação negativa em $t = 1,1$ h reforça esse comportamento: enquanto o IHMPCFF mantém respostas suaves e monotônicas, o CLMPC exibe transientes mais pronunciados, indicando menor amortecimento frente à redução abrupta da carga de CO_2 .

A análise das variáveis manipuladas (Figura 5.8) confirma essa tendência. A vazão de amina pobre (Flean), principal grau de liberdade utilizado para compensar variações na

alimentação de CO_2 , é ajustada de forma gradual e contínua pelo IHMPCFF, sem picos ou oscilações abruptas. Já no CLMPC, observa-se a presença de variações mais bruscas, especialmente após a segunda perturbação, refletindo maior esforço de controle para restabelecer o equilíbrio do sistema. As cargas térmicas dos refeedores permanecem praticamente constantes em ambos os casos, indicando que a estratégia de controle prioriza a manipulação do solvente, evitando alterações desnecessárias na demanda de vapor e contribuindo para a preservação do balanço energético da planta.

A superioridade do IHMPCFF torna-se mais evidente na análise da função econômica, apresentada na Figura 5.9. Durante a perturbação positiva em $t = 0,5$ h, o custo econômico acumulado apresenta um aumento temporário para ambos os controladores, associado ao maior consumo de solvente. No entanto, o IHMPCFF mantém uma trajetória mais suave, com menor inclinação e ausência de picos pronunciados, indicando menor penalidade econômica transitória. Em contraste, o CLMPC apresenta variações mais acentuadas na função custo, refletindo o impacto direto das oscilações nas variáveis manipuladas e controladas.

Após a perturbação negativa em $t = 1,1$ h, observa-se novamente que o IHMPCFF absorve a mudança de forma praticamente neutra do ponto de vista econômico, mantendo a função custo próxima ao regime anterior. O CLMPC, por sua vez, apresenta um desvio temporário mais expressivo, ainda que de curta duração. Em torno de $t \approx 2$ h, a atuação do RTO redefine o ponto ótimo de operação para ambos os controladores, resultando em um novo patamar da função econômica. A partir desse instante, as trajetórias de custo convergem, indicando desempenho econômico equivalente em regime permanente, porém com diferenças claras no comportamento transitório.

De forma geral, os resultados indicam que, embora em regime permanente ambos os controladores atinjam desempenho econômico semelhante, o IHMPCFF apresenta vantagens operacionais claras na dinâmica de rejeição de distúrbios. Sua atuação mais suave reduz variações desnecessárias de solvente, evita oscilações térmicas e minimiza o impacto econômico transitório. Essa robustez é particularmente relevante em condições reais de operação, nas quais variações de carga de gases de combustão são frequentes devido a flutuações na operação da caldeira, troca de combustível ou ajustes de potência. Assim, o IHMPC se mostra uma alternativa mais estável e eficiente para manter a operação dentro de faixas de custo e desempenho mais restritas, aumentando a confiabilidade operacional e reduzindo o desgaste de equipamentos ao longo do tempo.

5.2.2. Caso Mismatch

Neste segundo caso, o controlador preditivo foi aplicado diretamente ao modelo rigoroso da planta, com o objetivo de avaliar o desempenho das estratégias de controle sob condições mais próximas da operação industrial, incluindo a presença de descasamento entre modelo e processo. A avaliação do desempenho do sistema integrado RTO/MPC no modelo real da planta foi conduzida considerando a rejeição de perturbações, o comportamento dinâmico das variáveis controladas, o esforço de controle das variáveis manipuladas e o impacto econômico associado. No primeiro cenário, foi aplicada uma perturbação de +5% na fração molar de CO_2 do gás de entrada em $t = 1$ h, com o objetivo de avaliar a robustez das estratégias IHMPCFF e CLMPC frente a desassociação entre o modelo linear e modelo rigoroso (model mismatch).

Figura 5.10 - Saídas controladas 3° caso




Figura 5.11- Entradas Manipuladas 3° caso




Figura 5.12 - Função econômica 3º caso





Figura 5.13 - Métricas de desempenho dinâmicas



A Figura 5.10 apresenta a evolução temporal da taxa de captura de CO₂ (%CC). Antes da perturbação, ambos os controladores mantêm o rastreamento do setpoint com erro estacionário praticamente nulo. Após a aplicação da perturbação em $t = 1$ h, observa-se uma queda imediata da %CC, mais pronunciada no caso do CLMPC, que apresenta maior desvio máximo em relação ao setpoint e oscilações transitórias mais evidentes. O IHMPCFF, por sua vez, apresenta uma resposta mais amortecida, com menor pico de erro e recuperação mais suave, indicando maior robustez frente às incertezas do modelo real.

Além disso a Figuras 5.10 mostra as temperaturas dos reboleadores D-101 (Treb101) e D-102 (Treb102). Nota-se que, após a perturbação, o CLMPC induz oscilações significativas nas temperaturas, com desvios superiores a ± 10 K no caso do Treb101 e comportamento claramente subamortecido. Em contraste, o IHMPC mantém ambas as temperaturas próximas aos respectivos setpoints, com variações de baixa amplitude e rápida acomodação. Esse resultado evidencia que, no modelo real, o IHMPCFF apresenta melhor capacidade de desacoplamento entre controle de captura e controle térmico, reduzindo o estresse operacional dos equipamentos.

A Figura 5.11 apresenta a atuação das variáveis manipuladas: a vazão de amina pobre (Flean) e as cargas térmicas dos reboleadores (Qreb101 e Qreb102). Após a perturbação, ambos os controladores utilizam principalmente o aumento de Flean como mecanismo de compensação do excesso de CO₂. No entanto, o CLMPC apresenta variações mais abruptas e

oscilatórias, enquanto o IHMPC promove ajustes progressivos e mais suaves.

As cargas térmicas mostram comportamento semelhante: o CLMPC realiza correções mais agressivas, com picos e vales pronunciados, ao passo que o IHMPCFF mantém as cargas mais estáveis, indicando menor esforço de controle e maior preservação do balanço energético. Essa diferença é particularmente relevante no contexto industrial, pois oscilações frequentes de carga térmica estão associadas a maior consumo de vapor e desgaste operacional

A Figura 5.12 apresenta a evolução do custo econômico acumulado. Antes da perturbação, ambos os controladores operam em regime estável, com valores de custo semelhantes. Após a perturbação em $t = 1$ h, observa-se um aumento temporário do custo associado à necessidade de maior consumo de solvente e energia para manter a taxa de captura. O CLMPC apresenta maior variabilidade no custo acumulado durante o regime transitório, enquanto o IHMPCFF converge de forma mais suave para o novo patamar econômico.

Esse comportamento confirma que, embora ambos os controladores consigam restabelecer a operação, o IHMPCFF apresenta melhor compromisso entre desempenho dinâmico e eficiência econômica no modelo real da planta.

A Figura 5.13 apresenta as métricas de tempo de acomodação dentro de uma banda (settling time within a band) para a %CC, Treb101 e Treb102, respectivamente. Para a %CC, o IHMPCFF retorna à banda admissível rapidamente após a perturbação, enquanto o CLMPC apresenta múltiplas violações da banda, indicando maior sensibilidade ao model mismatch.

No caso das temperaturas dos refeedores, o contraste é ainda mais evidente: o CLMPC apresenta tempos de acomodação significativamente maiores e desvios máximos elevados, especialmente após $t = 1$ h, enquanto o IHMPC mantém as variáveis dentro da banda praticamente durante todo o horizonte de simulação. Esses resultados corroboram a superioridade do IHMPCFF em termos de rejeição de perturbações e robustez no modelo real.

De forma integrada, os resultados mostram que, no modelo real da planta, as diferenças entre as estratégias tornam-se mais pronunciadas do que no cenário nominal. O CLMPC, embora capaz de estabilizar o processo, apresenta maior variabilidade, maiores picos de erro e maior esforço de controle, características típicas de controladores mais sensíveis a incertezas paramétricas. O IHMPCFF, por outro lado, demonstra maior robustez, com respostas mais suaves, menores desvios máximos e melhor preservação das variáveis térmicas e econômicas.

A aplicação da perturbação de +5% na composição de CO_2 em $t = 1$ h evidenciou que o IHMPCFF é mais adequado para operação contínua em plantas reais, onde o descasamento entre modelo e processo é inevitável. Esses resultados reforçam a eficácia da arquitetura RTO/MPC e indicam que a adoção de estratégias intrinsecamente estáveis, como o IHMPCFF,

pode trazer ganhos operacionais significativos em cenários industriais reais.

6. CONCLUSÃO

Este trabalho apresentou o desenvolvimento, implementação e avaliação de uma arquitetura integrada de otimização em tempo real (RTO) e controle preditivo baseado em modelo (MPC) aplicada a uma planta de captura de CO₂ por absorção química com monoetanolamina (MEA), considerando simultaneamente aspectos dinâmicos, operacionais e econômicos. Inicialmente, foi identificado e validado um modelo dinâmico de baixa ordem, cuja aderência ao simulador Aspen Dynamics demonstrou ser adequada para fins de controle e otimização.

Com base nesse modelo, duas estratégias de controle econômico, CLMPC e IHMPCFF, foram projetadas e integradas a uma camada superior de RTO responsável pela determinação dos pontos ótimos de operação em regime permanente. Os resultados confirmaram a eficácia da arquitetura em duas camadas, na qual o RTO atua no reposicionamento econômico da planta em horizontes de tempo mais longos, enquanto a camada MPC assegura o rastreamento das variáveis controladas e a rejeição de perturbações em tempo real.

No cenário nominal, ambos os controladores foram capazes de manter a taxa de captura de CO₂ e as variáveis térmicas dentro das especificações operacionais, mesmo sob perturbações sucessivas. Entretanto, o IHMPCFF apresentou desempenho dinâmico superior, caracterizado por respostas mais suaves, menor esforço de controle e menor variabilidade da função custo durante regimes transitórios.

A aplicação do controle ao modelo real da planta evidenciou diferenças mais pronunciadas entre as estratégias, destacando a maior robustez do IHMPCFF frente a incertezas e descasamento de modelo. Nesse cenário, o IHMPCFF manteve as variáveis controladas dentro das bandas operacionais por maior fração do tempo, com menor oscilação térmica e comportamento econômico mais consistente quando comparado ao CLMPC.

Em síntese, os resultados demonstram que a arquitetura RTO/MPC proposta é adequada para a operação ótima de plantas de captura de CO₂, sendo o IHMPCFF uma alternativa mais robusta e operacionalmente consistente, especialmente em cenários realistas caracterizados por perturbações frequentes e incertezas de modelo. Esses achados reforçam o potencial de estratégias de controle econômico para aplicações industriais reais em sistemas de captura de carbono.

REFERÊNCIAS

- Abanades, J.C.; Arias, B.; Lyngfelt, A.; Mattisson, T.; Wiley, D.E.; Li, H.; Ho, M.T.; E. Mangano, S. Brandani. Emerging CO₂ capture systems. *Int. J. Greenhouse Gas Control* (2015), <http://dx.doi.org/10.1016/j.ijggc.2015.04.018>
- AKINOLA, Toluleke E. et al. Nonlinear model predictive control (NMPC) of the solvent-based post-combustion CO₂ capture process. **Energy**, v. 213, p. 118840, 2020. DOI: <https://doi.org/10.1016/j.energy.2020.118840>
- Alamo, T.; et al. (2012). Economic model predictive control: From steady-state to dynamic optimization. *Journal of Process Control*, 22(6), 1039–1054.
- Alamo, T.; et al. (2014). Integration of real-time optimization and model predictive control: Theoretical and industrial perspectives. *Computers & Chemical Engineering*, 71, 377–386.
- AL-MAMOORI, Ahmed et al. Carbon capture and utilization update. **Energy Technology**, v. 5, n. 6, p. 834-849, 2017. DOI: <https://doi.org/10.1002/ente.201600747>
- ASPENTECH. Aspen Plus® User Guide – V12.2: Rate-Based Model and RadFrac Column. Burlington, MA: Aspen Technology, 2023.
- AUSTGEN, D. M.; WATSON, T. F.; ROCHELLE, G. T.; CHEN, C. C. Model of vapor–liquid equilibria for aqueous acid gas–alkanolamine systems using the electrolyte-NRTL equation. *Industrial & Engineering Chemistry Research*, v. 28, p. 1060–1073, 1989.
- BOOT-HANDFORD, M. E.; et al. Advances in pre-combustion CO₂ capture technologies: integration and challenges. *International Journal of Greenhouse Gas Control*, v. 131, p. 103867, 2024.
- BRISTOL, E. H. On a new measure of interactions for multivariable process control. *IEEE Transactions on Automatic Control*, v. 11, n. 1, p. 133–134, 1996.
- BUDINIS, S., KREVER, S., DOWELL, N. MAC, BRANDON, N., & HAWKES, A. (2018). An assessment of CCS costs, barriers and potential. *Energy Strategy Reviews*.
- BUI, M.; et al. (2018). Dynamic modeling and control of amine-based post-combustion CO₂ capture plants. *Chemical Engineering and Processing*, 125, 104–118.
- BUI, M.; et al. Dynamic optimization of flexible CO₂ capture systems in power generation. *Energy Conversion and Management*, v. 304, 118790, 2024.
- BUI, Mai et al. Dynamic modelling and optimisation of flexible operation in post-combustion CO₂ capture plants—A review. **Computers & Chemical Engineering**, v. 61, p. 245-265, 2014. DOI: <http://dx.doi.org/10.1016/j.compchemeng.2013.11.015>
- Camacho, E. F.; Bordons, C.** *Model Predictive Control*. 2nd ed. London: Springer, 2013.
- CHAO, Cong et al. Post-combustion carbon capture. **Renewable and Sustainable Energy Reviews**, v. 138, p. 110490, 2021. DOI: <https://doi.org/10.1016/j.rser.2020.110490>
- CHATZIASTERIOU, Christos C.; KIKKINIDES, Eustathios S.; GEORGIADIS, Michael C.

Recent advances on the modeling and optimization of CO₂ capture processes. **Computers & Chemical Engineering**, p. 107938, 2022.

CHEN, C.-C.; BRITT, H. I.; BOSTON, J. F.; EVANS, L. B. Local Composition Model for Excess Gibbs Energy of Electrolyte Systems. Part I: Single Solvent, Single Completely Dissociated Electrolyte Systems. *AIChE J.* 1982, 28, 588–596.

CHEN, Y.; et al. Post-combustion CO₂ capture: recent progress in solvents and process intensification. *Applied Energy*, v. 349, p. 121599, 2023.

CORMOS, A.-M.; VASILE, M.; CRISTEA, M.-V., Flexible operation of CO₂ capture processes integrated with power plant using advanced control techniques. 12th International Symposium on Process Systems Engineering and 25th European Symposium on Computer Aided Process Engineering, *Computer Aided Chemical Engineering*, 2015; Vol. 37, pp 1547-1552.

DAI, Baoxin et al. Model predictive control of post-combustion CO₂ capture system for coal-fired power plants. In: **2017 36th Chinese Control Conference (CCC)**. IEEE, 2017. p. 9315-9320. DOI: <https://doi.org/10.23919/ChiCC.2017.8028841>

De Souza, J. P.; Odloak, D.; Zanin, A. C. (2010). Integrating economic optimization and control for industrial FCC units. *Journal of Process Control*, 20(2), 149–160.

De-Souza, G.; Odloak, D.; Zanin, A. Real time optimization (RTO) with model predictive control (MPC). *Comput. Chem. Eng.* 2010.34, 1999–2006

DINIZ FILHO, J. C.; NETTO, A. F. S. ; FERNANDES JUNIOR, H. G. L. ; MORAIS JUNIOR, A. A. . AVALIAÇÃO DE DESEMPENHO DE CONTROLADORES PREDITIVOS MULTIVARIÁVEIS EM UMA PLANTA DE CAPTURA DE CO₂. In: II CONGRESSO BRASILEIRO DE ENGENHARIA DE SISTEMAS EM PROCESSOS, 2022. ANAIS DO II CONGRESSO BRASILEIRO DE ENGENHARIA DE SISTEMAS EM PROCESSOS.

Ellis, M., & Christofides, P. D. (2015). Economic model predictive control for energy systems.

Esturilio, C. M. A. (2012). Economic MPC with infinite prediction horizon using the OPOM model. Ph.D. Thesis, University of São Paulo.

FLØ, Nina Enaasen et al. Dynamic model validation of the post-combustion CO₂ absorption process. **International Journal of Greenhouse Gas Control**, v. 41, p. 127-141, 2015. DOI: <https://doi.org/10.1016/j.ijggc.2015.07.003>

GARÐARSDÓTTIR S, NORMANN F, ANDERSSON K, PROLB K, EMILSDÓTTIR S, JOHNSON F. Post-combustion CO₂ capture applied to a state-of-the-art coal-fired power plant—The influence of dynamic process conditions. *Int J Greenhouse Gas Control* 2015;33:51–62.

GASPAR J, JØGENSEN JB, FOSBØL PL. Control of a post-combustion CO₂ capture plant during process start-up and load variations. *IFAC-Papers OnLine* 2015;48(8):580–5.

GASPAR, J.; et al. (2016). Dynamic modeling and control of post-combustion CO₂ absorption processes with amine solvents. *Energy Procedia*, 86, 255–264.

GASPAR, J.; et al. Advanced control and optimization for post-combustion CO₂ capture plants. *Computers & Chemical Engineering*, v. 91, p. 348–356, 2016.

GASPAR, J.; et al. Modeling, control, and optimization of CO₂ capture processes: a review of the state of the art. *International Journal of Greenhouse Gas Control*, v. 41, p. 142–157, 2015.

GASPAR, Jozsef et al. Controllability and flexibility analysis of CO₂ post-combustion capture using piperazine and MEA. **International Journal of Greenhouse Gas Control**, v. 51, p. 276–289, 2016. DOI: <https://doi.org/10.1016/j.ijggc.2016.06.003>

GÁSPÁR, Jozsef; CORMOȘ, Ana-Maria. Dynamic modeling and validation of absorber and desorber columns for post-combustion CO₂ capture. **Computers & Chemical Engineering**, v. 35, n. 10, p. 2044–2052, 2011. DOI: <https://doi.org/10.1016/j.compchemeng.2010.10.001>

Global CCS Institute. The Global Status of CCS: 2018, GCCSI, Oct. 2018. <https://www.globalccsinstitute.com/resources/global-status-report/>. [acessado em 6 de outubro 2023].

GREER, T. et al. A simulation study on the abatement of CO₂ emissions by de-absorption with monoethanolamine. **Environmental technology**, v. 31, n. 1, p. 107–115, 2010.

GREER, Timothy et al. A MODEL FOR ABATEMENT OF CO₂ EMISSIONS BY DE-ABSORPTION WITH MONOETHANOLAMINE. **International Journal of Energy for a Clean Environment**, v. 10, n. 1–4, 2009.

GUPTA, R.; et al. Hybrid CO₂ capture systems: techno-economic review and future directions. *Energy Reports*, v. 10, p. 405–422, 2024.

HARUN, Noorlisa et al. Dynamic simulation of MEA absorption process for CO₂ capture from power plants. **International Journal of Greenhouse Gas Control**, v. 10, p. 295–309, 2012. DOI: <https://doi.org/10.1016/j.ijggc.2012.06.017>

HE, Zhenrong; RICARDEZ-SANDOVAL, Luis A. Dynamic modelling of a commercial-scale CO₂ capture plant integrated with a natural gas combined cycle (NGCC) power plant. **International Journal of Greenhouse Gas Control**, v. 55, p. 23–35, 2016. DOI: <https://doi.org/10.1016/j.ijggc.2016.11.001>

IEA – International Energy Agency. Global Energy Review 2025. Paris: IEA, 2025. Disponível em: <https://www.iea.org/reports/global-energy-review-2025>

IEA, Electricity information 2017. IEA Publications; Aug. 2017. <https://euagenda.eu/publications/electricity-information-2017> . [acessado em 6 de outubro 2023].

IEA. CO₂ emissions from fuel combustion highlights (2017 edition). IEA Publications; Oct. 2017. <https://webstore.iea.org/co2-emissions-from-fuel-combustion> . [acessado em 6 de outubro 2023].

IEAGHG (2019). Cost of CO₂ capture using amines. Technical Report.

IEAGHG (2021). The role of CCUS in low-carbon power systems. Technical Report.

IPCC – Intergovernmental Panel on Climate Change. AR6 Synthesis Report: Climate Change 2023. Geneva: IPCC, 2023.

JAYARATHNA, Sanoja A.; LIE, Bernt; MELAAEN, Morten C. Amine based CO₂ capture plant: Dynamic modeling and simulations. **International Journal of Greenhouse Gas Control**, v. 14, p. 282-290, 2013. DOI:<https://doi.org/10.1016/j.ijggc.2013.01.028>

JAYARATHNA, Sanoja A.; LIE, Bernt; MELAAEN, Morten C. Dynamic modelling of the absorber of a post-combustion CO₂ capture plant: Modelling and simulations. **Computers & chemical engineering**, v. 53, p. 178-189, 2013. DOI:<https://doi.org/10.1016/j.compchemeng.2013.03.002>

KENIG, E. Y.; SCHNEIDER, Ralph; GÓRAK, Andrzej. Reactive absorption: Optimal process design via optimal modelling. **Chemical engineering science**, v. 56, n. 2, p. 343-350, 2001. DOI:[https://doi.org/10.1016/S0009-2509\(00\)00234-7](https://doi.org/10.1016/S0009-2509(00)00234-7)

KISTER, H. Z. Distillation Design. New York: McGraw-Hill, 1992.

KNUDSEN, Jacob N. et al. Experience with CO₂ capture from coal flue gas in pilot-scale: Testing of different amine solvents. **Energy Procedia**, v. 1, n. 1, p. 783-790, 2009. DOI:<https://doi.org/10.1016/j.egypro.2009.01.104>

Lawal A, Wang M, Stephenson P, Koumpouras G, Yeung H. Dynamic modelling and analysis of post-combustion CO₂ chemical absorption process for coal-fired power plants. *Fuel* 2010;89:2791–801

Lawal A, Wang M, Stephenson P, Obi O. Demonstrating full-scale post combustion CO₂ capture for coal-fired power plants through dynamic modelling and simulation. *Fuel* 2012;101:115–28.

LAWAL, A.; et al. Dynamic modeling and simulation of CO₂ chemical absorption process for coal-fired power plants. *Fuel*, v. 101, p. 115–128, 2012.

LAWAL, Adekola et al. Dynamic modelling of CO₂ absorption for post combustion capture in coal-fired power plants. **Fuel**, v. 88, n. 12, p. 2455-2462, 2009. DOI:<https://doi.org/10.1016/j.fuel.2008.11.009>

Le Moullec, Y., & Kanniche, M. (2011). Screening of flowsheet modifications for an efficient monoethanolamine (MEA) based post-combustion CO₂ capture. *Int. J. Greenhouse Gas Control*.

LI, H.; et al. Chemical looping combustion: current status and scale-up challenges. *Progress in Energy and Combustion Science*, v. 96, 101092, 2023.

LI, H.; et al. Model predictive control of CO₂ capture processes. *Industrial & Engineering Chemistry Research*, v. 51, n. 47, p. 15487–15498, 2012.

LIANG, Xiufan et al. Nonlinearity analysis and multi-model modeling of an MEA-based post-combustion CO₂ capture process for advanced control design. **Applied Sciences**, v. 8, n. 7, p. 1053, 2018. DOI:<https://doi.org/10.3390/app8071053>

Lin Y, Chang C, Wong D, Jang S, Ou J. Control strategies for flexible operation of power plant with CO₂ capture plant. Proceedings of the 11th international symposium on process systems engineering. 2012. p. 1366–71

Lin Y, Pan T, Wong D, Jang S, Chi Y, Yeh C. Plant wide control of CO₂ capture by absorption and stripping using monoethanolamine solution. Ind Eng Chem Res 2011;50:1338–45.

LIN, Yu-Jeng et al. Plantwide control of CO₂ capture by absorption and stripping using monoethanolamine solution. **Industrial & Engineering Chemistry Research**, v. 50, n. 3, p. 1338–1345, 2011. DOI: <https://doi.org/10.1021/ie100771x>

Ljung, L. *System Identification: Theory for the User*. 2nd ed. Upper Saddle River: Prentice Hall, 1999.

Lucia, S.; Finkler, T.; Engell, S. Multi-stage nonlinear model predictive control applied to a semi-batch polymerization reactor. *Journal of Process Control*, v. 23, n. 9, p. 1306–1319, 2013.

Lucquiaud, M.; Gibbins, J. (2020). Flexible operation of post-combustion CO₂ capture plants at fossil-fired power stations. *International Journal of Greenhouse Gas Control*, 93, 102876.

LUCQUIAUD, M.; GIBBINS, J. Flexible operation of post-combustion CO₂ capture plants at fossil-fired power stations. *International Journal of Greenhouse Gas Control*, v. 93, 102876, 2020.

MA, Chenbin et al. Economic model predictive control for post-combustion CO₂ capture system based on MEA. **Energies**, v. 14, n. 23, p. 8160, 2021. DOI:<https://doi.org/10.3390/en14238160>

MAC DOWELL, N.; et al. Flexible operation of CO₂ capture systems: challenges, opportunities and modelling needs. *Progress in Energy and Combustion Science*, v. 86, 100965, 2021.

MAC DOWELL, N.; SHAH, N. The role of dynamic modeling and control in reducing the cost of CO₂ capture and storage for power generation. *Journal of Process Control*, v. 33, p. 126–138, 2015.

MACIEJOWSKI, J. M. *Predictive Control With Constraints*. Prentice Hall, Harlow, Eengland, 2002.

Manaf NA, Cousins A, Feron P, Abbas A. Dynamic modelling. Identification and preliminary control analysis of an amine-based post-combustion CO₂ capture pilot plant. *J Cleaner Prod* 2016;113:635–53.

Marlin, T. E.; Hrymak, A. N. (1996). Real-time operations optimization of continuous processes. *Aiche Symposium Series*, 92(312), 156–164.

Mechleri E, Lawal A, Ramos A, Davison J, Mac Dowell N. Process control strategies for flexible operation of post-combustion CO₂ capture plants. *Int J Greenhouse Gas Control* 2017;57:14–25.

MNIH, V.; KAVUKCUOGLU, K.; SILVER, D.; GRAVES, A.; ANTONOGLU, I.; WIERSTRA, D.; RIEDMILLER, M. **Playing atari with deep reinforcement learning**. arXiv preprint arXiv:1312.5602, 2013.

Nittaya T, Douglas PL, Croiset E, Ricardez-Sandoval LA. Dynamic modelling and evaluation of an industrial-scale CO₂ capture plant using monoethanolamine absorption processes. *Ind Eng Chem Res* 2014;53:11411–26.

NITTAYA, Thanita et al. Dynamic modeling and evaluation of an industrial-scale CO₂ capture plant using monoethanolamine absorption processes. **Industrial & Engineering Chemistry Research**, v. 53, n. 28, p. 11411-11426, 2014. DOI: <https://doi.org/10.1021/ie500190p>

NITTAYA, Thanita et al. Dynamic modelling and control of MEA absorption processes for CO₂ capture from power plants. **Fuel**, v. 116, p. 672-691, 2014. DOI:<https://doi.org/10.1016/j.fuel.2013.08.031>

NOERES, Christoph; KENIG, E. Y.; GÓRAK, Andrzej. Modelling of reactive separation processes: reactive absorption and reactive distillation. **Chemical Engineering and Processing: Process Intensification**, v. 42, n. 3, p. 157-178, 2003.

NYTTAYA, V.; et al. Dynamic modeling and control of post-combustion CO₂ capture using amine solvents. *Energy Procedia*, v. 63, p. 1280–1287, 2014.

ODLOAK, D. Extended robust model predictive control. *AIChE Journal*, v. 50, n. 8, p.1824-1836, 2004.

PACHECO, M. A. Modeling and optimization of CO₂ capture by aqueous monoethanolamine. PhD Thesis, The University of Texas at Austin, 1998.

PATARO, I. M. L; JUAN, D. G; MARCUS, V. A. C., JOSÉ L. G; MANUEL B. A stabilizing predictive controller with implicit feedforward compensation for stable and time-delayed systems. **Journal of Process Control**, v. 115, p. 12-26, 2022

Patrón, A.; Ricardez-Sandoval, L. A. (2022). Economic model predictive control of CO₂ capture plants under process uncertainty. *Computers & Chemical Engineering*, 157, 107615.

PATRÓN, A.; RICARDEZ-SANDOVAL, L. A. Economic model predictive control for post-combustion CO₂ capture processes. *Computers & Chemical Engineering*, v. 176, 108390, 2023.

Patrón, G. & Ricardez-Sandoval, L. (2022). Real-time economic optimization of post-combustion CO₂ capture plants. *Computers & Chemical Engineering*.

Patrón, R.; Ricardez-Sandoval, L. A. Economic model predictive control of chemical processes: A review. *Computers & Chemical Engineering*, v. 159, 107646, 2022.

Porfirio, C. A.; Odloak, D. (2011). Economic model predictive control applied to an industrial distillation column. *Control Engineering Practice*, 19, 1185–1193.

PORFIRIO, C. R. **Implantação de otimizador online acoplado ao controle preditivo (MPC) de uma coluna de Tolueno**. 2011. Tese de Doutorado. Universidade de São Paulo.

POSCH, Sebastian; HAIDER, Markus. Dynamic modeling of CO₂ absorption from coal-fired

power plants into an aqueous monoethanolamine solution. **Chemical engineering research and design**, v. 91, n. 6, p. 977-987, 2013. DOI: <https://doi.org/10.1016/j.cherd.2012.09.016>

Qin, S. J.; Badgwell, T. A. A survey of industrial model predictive control technology. *Control Engineering Practice*, v. 11, n. 7, p. 733–764, 2003.

Rackley, Stephen A. Carbon Capture and Storage. Butterworth-Heinemann, 2nd Edition, 2017.

Rawlings, J. B., Mayne, D. Q., & Diehl, M. (2017). Model Predictive Control: Theory, Computation, and Design.

REDDY, S.; et al. Operational flexibility and transient performance of carbon capture systems integrated with natural gas combined cycle plants. *Applied Energy*, v. 321, 120822, 2022.

Rochelle, G. T. (2009). Amine Scrubbing for CO₂ Capture. Science.

RODRIGUES, M.A.; ODLOAK, D. An infinite horizon model predictive control for stable and integrating processes. *Computers & Chemical Engineering*, v. 27, n. 8-9, p.1113-1128, 2003

RODRIGUES, M.A.; ODLOAK, D. MPC for stable linear systems with model uncertainty. *Automatica*, v. 39, n. 4, p.569-583, 2003.

Rodriguez J, Andrade A, Lawal A, Samsatli N, Calado S, Lafitte T, et al. An integrated framework for the dynamic modelling of solvent-based CO₂ capture processes. *Energy Procedia* 2014;63:1206–17.

Rotava, J.; Zanin, A. C. (2005). Hierarchical structures for integrating optimization and control in process systems. *Brazilian Journal of Chemical Engineering*, 22(2), 231–241.

Sahraei MH, Ricardez-Sandoval LA. Controllability and optimal scheduling of a CO₂ capture plant using model predictive control. *Int J Greenhouse Gas Control* 2014;30:58–71

SALVINDER, K. M. S. et al. An overview on control strategies for CO₂ capture using absorption/stripping system. **Chemical Engineering Research and Design**, v. 147, p. 319-337, 2019. DOI:<https://doi.org/10.1016/j.cherd.2019.04.034>

SALVINDER, K. M. S. et al. Dynamic modelling, simulation and basic control of CO₂ absorption based on high pressure pilot plant for natural gas treatment. **International Journal of Greenhouse Gas Control**, v. 70, p. 164-177, 2018. DOI:<https://doi.org/10.1016/j.ijggc.2017.12.014>

SHALABY, Abdelhamid et al. A machine learning approach for modeling and optimization of a CO₂ post-combustion capture unit. **Energy**, v. 215, p. 119113, 2021. DOI:<https://doi.org/10.1016/j.energy.2020.119113>

Sharifzadeh M, Shah N. MEA-based CO₂ capture integrated with natural gas combined cycle or pulverized coal power plants: operability and controllability through integrated design and control. *J Cleaner Prod* 2019;207:271–83.

SHARIFZADEH, M.; et al. Application of advanced process control and optimization for efficient CO₂ capture from flue gas. *Computers & Chemical Engineering*, v. 122, p. 77–92, 2019.

SHEN, Ming-Tien; CHEN, Yih-Hang; CHANG, Hsuan. Simulation of the Dynamics and Control Responses of the Carbon Dioxide Chemical Absorption Process using Aspen Custom Modeler. *Energy Procedia*, v. 158, p. 4915-4920, 2019. DOI: <https://doi.org/10.1016/j.egypro.2019.01.700>

SILVER, D.; HUBERT, T.; SCHRITTWIESER, J.; ANTONOGLOU, I.; LAI, M.; GUEZ, A.; LANCTOT, M.; SIFRE, L.; KUMARAN, D.; GRAEPEL, T.; LILICRAP, T.; SIMONYAN, K.; HASSABIS, D. **A general reinforcement learning algorithm that masters chess, shogi, and Go through self-play**. *Science*, v. 362, n. 6419, p. 1140-1144, 2018.

SINGH, R.; et al. Oxy-fuel combustion systems: modeling, energy penalty, and CO₂ capture performance. *Energy Conversion and Management*, v. 301, 117896, 2024.

SMITH, P.; et al. Direct air capture (DAC) systems: scaling, energy requirements, and deployment pathways. *Nature Climate Change*, v. 14, p. 114–123, 2024.

TAYLOR, R.; KRISHNA, R. *Multicomponent Mass Transfer*. New York: John Wiley & Sons, 1993.

TRAPP, Carsten et al. Dynamic modelling and validation of pre-combustion CO₂ absorption based on a pilot plant at the Buggenum IGCC power station. *International Journal of Greenhouse Gas Control*, v. 36, p. 13-26, 2015. DOI: <https://doi.org/10.1016/j.jggc.2015.02.005>

TSAY, Calvin et al. Rate-based modeling and economic optimization of next-generation amine-based carbon capture plants. *Applied Energy*, v. 252, p. 113379, 2019. DOI: <https://doi.org/10.1016/j.apenergy.2019.113379>

UNFCCC. Historic Paris Agreement on Climate Change, from <http://newsroom.unfccc.int/unfccc-newsroom/finale-cop21/>. [acessado em 6 de outubro 2023].

Van Overschee, P.; De Moor, B. *Subspace Identification for Linear Systems: Theory, Implementation, Applications*. Boston: Kluwer Academic Publishers, 1996.

WANG, H.; GE, Z. **Internal Environment Controlling Algorithm of DMF Distillation Column based on Reinforcement Learning**. In: 2020 IEEE 9th Joint International Information Technology and Artificial Intelligence Conference (ITAIC). IEEE, p. 1479-1483, 2020.

WANG, J.; et al. Metal-organic frameworks for CO₂ adsorption: from materials to process integration. *Journal of CO₂ Utilization*, v. 73, 102399, 2023.

WANG, Meihong et al. Post-combustion CO₂ capture with chemical absorption: A state-of-the-art review. *Chemical engineering research and design*, v. 89, n. 9, p. 1609-1624, 2011. DOI: <https://doi.org/10.1016/j.cherd.2010.11.005>

WILBERFORCE, Tabbi et al. Progress in carbon capture technologies. *Science of The Total Environment*, v. 761, p. 143203, 2021. DOI: <https://doi.org/10.1016/j.scitotenv.2020.143203>

Wilcox, Jennifer. Carbon Capture. Springer, 2012.

Wqz EU. Global and European sea-level rise, from <http://www.eea.europa.eu/data-and-maps/indicators/sea-level-rise-2/assessment> . [acessado em 6 de outubro 2023].

WU, Xiao et al. Solvent-based post-combustion CO₂ capture for power plants: A critical review and perspective on dynamic modelling, system identification, process control and flexible operation. **Applied Energy**, v. 257, p. 113941, 2020. DOI: <https://doi.org/10.1016/j.apenergy.2019.113941>

ZHANG, L.; et al. Advanced membranes for CO₂ separation: trends and scale-up challenges. *Separation and Purification Technology*, v. 333, 124015, 2024.

ZHANG, Qiang; TURTON, Richard; BHATTACHARYYA, Debangsu. Development of model and model-predictive control of an MEA-based postcombustion CO₂ capture process. **Industrial & Engineering Chemistry Research**, v. 55, n. 5, p. 1292-1308, 2016. DOI: <https://doi.org/10.1021/acs.iecr.5b02243>

ZHANG, Ying et al. Rate-based process modeling study of CO₂ capture with aqueous monoethanolamine solution. **Industrial & engineering chemistry research**, v. 48, n. 20, p. 9233-9246, 2009. DOI: <https://doi.org/10.1021/ie900068k>

ZIAII, Sepideh; ROCHELLE, Gary T.; EDGAR, Thomas F. Dynamic modeling to minimize energy use for CO₂ capture in power plants by aqueous monoethanolamine. **Industrial & Engineering Chemistry Research**, v. 48, n. 13, p. 6105-6111, 2009. DOI: <https://doi.org/10.1021/ie801385q>