

UNIVERSIDADE FEDERAL DE SÃO CARLOS
DEPARTAMENTO DE ENGENHARIA QUÍMICA
TRABALHO DE GRADUAÇÃO
PROF. ORIENTADOR: RODRIGO BÉTTEGA

**INTELIGÊNCIA ARTIFICIAL APLICADA AO CONTROLE DE PROCESSOS EM
BIORREATORES**

BRUNA FAGÁ REIS – 802317

SÃO CARLOS

2025

Dedico este trabalho à minha mãe, cuja presença, incentivo e confiança foram essenciais em cada etapa desta jornada. Ao meu namorado, que esteve ao meu lado desde o início da graduação, oferecendo apoio ao longo de todo o caminho. Dedico também aos meus avós, que, mesmo não estando mais aqui, deixaram em mim valores, força e ensinamentos que tornaram possível chegar até este momento. A memória deles acompanha cada conquista minha.

AGRADECIMENTO

Agradeço primeiramente ao meu orientador, Rodrigo Béttega, cuja orientação, apoio e acompanhamento constante foram indispensáveis para a realização deste trabalho.

Registro também meu reconhecimento ao professor Antônio Carlos Luperni Horta. Seus ensinamentos e a experiência prática proporcionada na disciplina de Desenvolvimento de Processos Químicos foram essenciais para a compreensão dos conceitos aplicados e enriqueceram a construção da parte teórica deste trabalho.

Agradeço também às minhas amigas Julia, Larissa, Letícia e Ana Beatriz, que compartilharam comigo cada fase dessa trajetória acadêmica. Juntas enfrentamos desafios, celebramos conquistas e construímos momentos que levarei para sempre comigo.

RESUMO

O presente trabalho analisa a aplicação da Inteligência Artificial (IA) no controle de processos em biorreatores, com ênfase em dornas fermentativas do setor sucroalcooleiro. A pesquisa foi conduzida por meio de revisão bibliográfica e análise comparativa de estudos desenvolvidos na Universidade de São Paulo - USP e na Universidade Estadual de Campinas - UNICAMP, que aplicam redes neurais artificiais integradas a controladores preditivos baseados em modelo (MPC - *Model Predictive Control*). Complementarmente, foi elaborada uma análise bibliométrica com apoio do *software* Cytoscape, permitindo mapear a evolução das pesquisas e identificar tendências emergentes. Os resultados evidenciam que o uso de IA neste tipo de controle apresenta ganhos significativos de estabilidade, robustez e eficiência, sobretudo em sistemas multivariáveis e não lineares, como os biotecnológicos. A incorporação de técnicas como *soft sensors*, gêmeos digitais e modelos híbridos amplia a capacidade de previsão e a flexibilidade operacional, representando um avanço em direção à Indústria 4.0. O estudo apontou que o uso dessas tecnologias em usinas de etanol é uma alternativa interessante para melhorar a eficiência energética e elevar a produtividade. Porém, a pesquisa também indica que ainda há obstáculos relacionados aos dados, à compreensão dos modelos e à integração dos novos sistemas com os já existentes.

Palavras-chave: controle de processos; inteligência artificial; redes neurais artificiais; controle preditivo; fermentação alcoólica; indústria sucroalcooleira.

ABSTRACT

This work analyzes the application of Artificial Intelligence (AI) in process control of bioreactors, with emphasis on fermentative tanks used in the Brazilian sugarcane industry. The study was conducted through a bibliographic review and comparative analysis of research carried out at the University of São Paulo (USP) and the State University of Campinas (UNICAMP), which employ artificial neural networks integrated with model-based predictive controllers (MPC). Additionally, a bibliometric analysis using Cytoscape software was performed to map research evolution and identify emerging trends. The findings show that AI-based control strategies significantly improve process stability, robustness, and efficiency, especially in nonlinear and multivariable systems such as biotechnological processes. The incorporation of *soft sensors*, digital twins, and hybrid models enhances predictive accuracy and operational flexibility, representing an important step toward Industry 4.0. In the Brazilian context, implementing these technologies in ethanol plants appears to be a promising strategy for energy optimization and productivity increase, although challenges remain regarding data quality, model interpretability, and system integration.

Keywords: process control; artificial intelligence; neural networks; predictive control; alcoholic fermentation; sugar-energy industry.

LISTA DE ILUSTRAÇÃO

Figura 01 - Fluxograma do controlador PID.....	16
Figura 02 - Exemplo de resposta do processo durante o teste.....	17
Figura 03 - Resposta do processo em malha aberta.....	18
Figura 04- Resposta do processo de primeira ordem em malha aberta.....	19
Figura 05- Funcionamento do MPC.....	20
Figura 06: Matriz dinâmica G.....	22
Figura 07 - Ciclo integrado completo de uma biorrefinaria.....	23
Figura 08 - Estrutura funcional de um controlador preditivo baseado em modelo (MPC).....	25
Figura 09 - Comparação entre o desempenho dos controladores NDQMC e NNSMPC.....	27
Figura 10- Diagrama esquemático da coluna fracionadora da Shell.....	29
Figura 11- Respostas simuladas das variáveis controladas (y_1 a y_7) da coluna fracionadora da Shell utilizando o controlador neural NNTDMPC.....	31
Figura 12 - Diagrama esquemático da planta de fermentação extrativa contínua.....	33
Figura 13 - Distribuição da produção global de etanol por região (2024).....	38
Figura 14- Fluxograma Integrado de Relações entre Controle de Processos, Inteligência Artificial e Bioprocessos.....	48
Figura A.1. Planilha codes - Análise bibliométrica.....	53
Figura A.2 - Planilhas edges - Análise bibliométrica.....	54

LISTA DE TABELAS

Tabela 01 - Sintonia segundo Ziegler e Nichols, em malha fechada.....	17
Tabela 02 - Sintonia segundo Ziegler e Nichols, em malha aberta.....	19
Tabela 03 – Riscos e estratégias de mitigação na implementação de IA em fermentação alcoólica.....	44

LISTA DE ABREVIATURAS

p:v – proporção massa/volume

°C – grau Celsius

LISTA DE SIGLAS

ANN – *Artificial Neural Network*

CGEE – Centro de Gestão e Estudos Estratégicos

DMC – *Dynamic Matrix Control*

IA – Inteligência Artificial

IIoT – *Industrial Internet of Things*

MIMO – *Multiple Input Multiple Output*

MPC – *Model Predictive Control*

NDQMC – *Nonlinear Dynamic Quadratic Model Control*

NNMPC – *Neural Network Model Predictive Control*

NNSMPC – *Neural Network State Model Predictive Control*

NNTDMPC – *Neural Network Time-Domain Model Predictive Control*

PID – *Proportional–Integral–Derivative*

RL – *Reinforcement Learning*

SCADA – *Supervisory Control and Data Acquisition*

SVR – *Support Vector Regression*

SISO – *Single Input Single Output*

XAI – *Explainable Artificial Intelligence*

UNICAMP – Universidade Estadual de Campinas

USP – Universidade de São Paulo

LISTA DE SÍMBOLOS

- $e(t)$ – Erro do sistema
- $u(t)$ – Variável manipulada
- $y(t)$ – Variável controlada (saída)
- $r(t)$ – Referência (*setpoint*)
- K_p – Ganho proporcional
- K_i – Ganho integral
- K_d – Ganho derivativo
- K_u – Ganho último
- P_u – Período último
- Δu – Variação da ação de controle
- ΔY – Variação da saída
- τ (tau) – Constante de tempo
- θ ou L – Tempo morto
- N_p – Horizonte de predição
- N_c – Horizonte de controle
- λ – Peso do esforço de controle

SUMÁRIO

1. INTRODUÇÃO.....	12
2. FUNDAMENTAÇÃO TEÓRICA.....	13
2.1. Controle PID.....	14
2.1.1 Metodologia de Ziegler-Nichols.....	16
2.1.1.1 Malha fechada.....	16
2.1.1.2. Malha aberta.....	18
2.2 Controle MPC.....	19
3. CONTROLE DE PROCESSOS EM BIORREATORES.....	23
4. INTELIGÊNCIA ARTIFICIAL NA INDÚSTRIA QUÍMICA.....	25
5. APLICAÇÃO NA INDÚSTRIA SUCROALCOOLEIRA.....	37
5.1. Panorama tecnológico atual.....	39
5.2. Justificativa técnica para aplicação em dornas fermentativas.....	41
5.3 Cenários de aplicação propostos.....	42
5.4 Tendências futuras e visão estratégica.....	45
5.5 Análise bibliométrica.....	46
5.5.1. Metodologia aplicada.....	46
5.5.2. Análise de correlações.....	47
6. CONCLUSÃO.....	48
7. REFERÊNCIAS BIBLIOGRÁFICAS.....	50
APÊNDICE A - Planilhas.....	53

1. INTRODUÇÃO

O avanço das tecnologias digitais transformou significativamente a engenharia química atual, sobretudo no campo do controle de processos. A consolidação da Indústria 4.0 e a crescente disponibilidade de dados operacionais em tempo real impulsionaram o desenvolvimento de estratégias de controle mais inteligentes, capazes de trabalhar com sistemas não lineares, multivariáveis e sujeitos a incertezas. Nesse contexto, a Inteligência Artificial (IA) surge como uma das ferramentas mais promissoras, oferecendo novos paradigmas de modelagem, previsão e tomada de decisão aplicáveis a processos complexos. Dentre esses processos biotecnológicos e de separação que podem apresentar múltiplas variáveis de controle.

A motivação para este estudo se dá pela necessidade de compreender e explorar o potencial da IA como ferramenta de intensificação e otimização de processos químicos. Embora controladores preditivos e métodos clássicos baseados em modelos fenomenológicos ainda predominem na prática industrial, eles frequentemente apresentam limitações diante de comportamentos altamente não lineares e restrições dinâmicas. A IA, por sua vez, permite o aprendizado direto a partir de dados de operação, o que viabiliza o desenvolvimento de controladores adaptativos e de modelos híbridos capazes de capturar a complexidade dos sistemas reais. Essa abordagem representa um avanço relevante para o cenário brasileiro, especialmente nas indústrias de base biotecnológica, como o setor sucroalcooleiro, em que o controle eficiente da fermentação é determinante para a produtividade e sustentabilidade econômica.

O trabalho se insere no campo de intersecção entre engenharia de controle, ciência de dados e bioprocessos, refletindo uma tendência global de integração entre IA e engenharia de processos. Nesse sentido, o trabalho usa como base metodológica a análise e comparação de pesquisas desenvolvidas em instituições de referência, como a Universidade de São Paulo - USP e a Universidade Estadual de Campinas - UNICAMP, que aplicaram redes neurais artificiais em controladores preditivos *model-based*, abordando tanto processos convencionais (como a coluna fracionadora da Shell) quanto biotecnológicos (como a fermentação extrativa contínua). A partir dessa fundamentação, propõe-se uma análise crítica e a construção de cenários futuros de aplicação da IA em sistemas fermentativos industriais, com ênfase na realidade das usinas brasileiras de etanol.

Além disso, o estudo incorpora uma abordagem bibliométrica e visual, representada pelo fluxograma (mapa de coocorrência) construído com base em dados estruturados de publicações com temas análogos utilizados para ilustrar o método de análise de redes semântica. A elaboração desse fluxograma seguiu um protocolo sistemático de coleta, processamento e visualização de dados, garantindo reprodução e rigor metodológico.

A partir desse panorama, busca-se demonstrar que a integração entre técnicas de IA e o controle de processos químicos constitui não apenas um avanço técnico, mas também uma mudança na forma de compreender, modelar e otimizar sistemas industriais. Assim, contribuindo para o debate acadêmico sobre a transformação digital na engenharia química, analisando criticamente as possibilidades de aplicação da IA em processos reais, em especial no controle fermentativo do setor sucroalcooleiro, e apontando caminhos para sua implementação prática e sustentável.

2. FUNDAMENTAÇÃO TEÓRICA

O controle de processos é a prática de monitorar e otimizar variáveis industriais com o objetivo de garantir que um sistema opere de forma estável, eficiente e dentro das especificações desejadas. Para isso, empregam-se sensores, controladores e atuadores que ajustam continuamente o processo, compensando perturbações internas e externas (CAMPOS; TEIXEIRA, 2010).

Nos processos industriais, especialmente aqueles instáveis ou sujeitos a variações, o uso de sistemas de controle automático é indispensável para manter variáveis críticas próximas de seus valores de referência (*setpoint*). Pode-se citar o princípio básico de um sistema de controle em malha fechada, que é atuar sobre as variáveis manipuladas a partir do erro entre o valor desejado e o valor real da variável controlada, cálculo este sintetizado em algoritmos que definem, em tempo real, a ação corretiva adequada (CAMPOS; TEIXEIRA, 2010).

Entre os métodos clássicos mais estudados, o controlador Proporcional Integral Derivativo (PID) é o mais difundido e amplamente aplicado em processos químicos e biológicos na indústria. Ele ajusta a variável manipulada para minimizar o erro, combinando três termos: a ação proporcional, que responde imediatamente às variações; a integral, que elimina o erro estacionário; e a derivativa, que antecipa tendências futuras. Este método é típico dada sua simplicidade, ao baixo custo computacional e ao bom desempenho em processos de baixa complexidade.

No contexto da fermentação alcoólica, por exemplo, o PID é aplicado de forma recorrente no controle da temperatura, variável crítica para garantir a máxima eficiência

metabólica das leveduras, evitar a formação de subprodutos indesejáveis e assegurar a conversão eficiente de açúcares em etanol (LIMA; BASSO; AMORIM, 2001). Além disso, a automação baseada nesse tipo de controlador contribui para a redução de custos operacionais, tanto pela minimização de desperdícios de energia e matérias-primas quanto pela diminuição da necessidade de intervenções manuais de operadores, resultando em maior sustentabilidade do processo.

Apesar de sua relevância histórica e de ainda ser predominante na prática industrial, o PID apresenta limitações diante de processos de maior complexidade, não linearidade acentuada e múltiplas variáveis interagindo entre si. Nesses casos, métodos avançados como o Controle Preditivo Baseado em Modelo (*Model Predictive Control – MPC*) começaram a ser consolidados como uma alternativa mais segura, estável e confiável. O MPC utiliza explicitamente um modelo matemático do processo para prever o comportamento futuro das variáveis controladas ao longo de um horizonte de tempo e, a partir dessas previsões, resolve um problema de otimização que determina a sequência de ações de controle mais adequadas. Apenas a primeira ação calculada é implementada, sendo o procedimento repetido a cada novo instante de amostragem, incorporando as medições atualizadas do sistema (MARQUES, 2019).

Esse tipo de controle apresenta algumas vantagens em relação ao PID, destacando-se a capacidade de trabalhar com sistemas multivariáveis, a inclusão clara de restrições operacionais de segurança e qualidade, e a atuação antecipativa, que permite evitar desvios antes que eles ocorram. Além disso, o MPC pode ser integrado a estratégias de otimização de processo em tempo real, ampliando os ganhos econômicos e energéticos da planta industrial. Por outro lado, sua eficácia depende da qualidade do modelo matemático escolhido e exige maior capacidade computacional, o que pode dificultar sua aplicação em determinadas situações industriais.

2.1. Controle PID

O controle PID (Proporcional Integral Derivativo) é uma das técnicas mais utilizadas para o controle de variáveis contínuas, devido à sua simplicidade no ajuste de parâmetros (CAMPOS; TEIXEIRA, 2010). Esse controle é baseado em um algoritmo matemático que visa garantir o controle preciso de uma variável dentro de um sistema, permitindo que ele opere de maneira estável no ponto de ajuste definido, mesmo diante de variações ou perturbações que possam comprometer sua estabilidade. A aplicação do PID é versátil e pode

ser encontrada em diversos contextos que demandam o controle de variáveis contínuas, como: rotação, nível, pressão, vazão, temperatura, controle de tensão, entre outros.

O controlador PID começa calculando o erro entre a variável controlada e o valor desejado, sendo o erro definido como a diferença entre o valor desejado (*setpoint*) e o valor real da variável, conforme ilustrado na Equação 1.

$$e(t) = \text{Set point} - \text{Valor medido pelo sensor} \quad (1)$$

O controle PID possui ação de um termo proporcional, um integral e um derivativo, podendo ser descrito pela seguinte equação:

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

onde u é a variável manipulada, K_p é ganho proporcional, K_i é o ganho integral, K_d é o ganho derivativo e E é o erro ou desvio.

No controle PID, cada ação desempenha uma função específica. A ação proporcional atua diretamente diminuindo o erro, contribuindo para a estabilização do sistema, mas não garante que a variável atinja exatamente o valor desejado (*setpoint*), resultando em um desvio chamado *off-set*. A ação proporcional atua corrigindo o erro do sistema ao multiplicar o ganho proporcional pelo erro, aplicando uma correção com maior amplitude para manter a estabilidade da variável (OGATA, 2012).

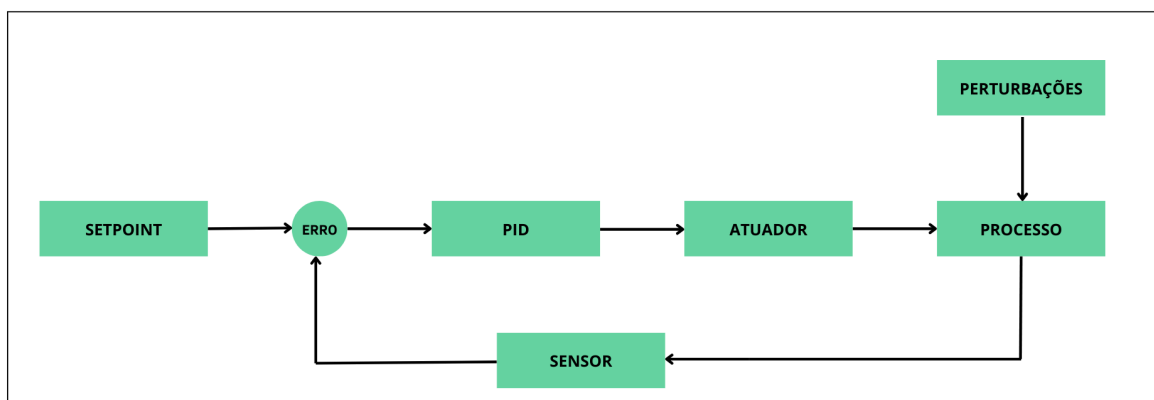
Já a ação integral, por sua vez, elimina o *off-set*, garantindo que a variável permaneça próxima ao valor desejado, mesmo após um distúrbio. Isso significa que, mesmo diante de uma variação brusca nas condições de operação, a variável tende a voltar para o *setpoint*. A ação integral realiza essa correção ao integrar o erro ao longo do tempo. Assim, quanto maior o tempo em que o erro persiste, maior será a amplitude da ação integral (OGATA, 2012).

A ação derivativa, por fim, fornece uma resposta antecipativa ao sistema, evitando que o desvio se agrave em processos onde a correção tende a ser lenta em comparação com a velocidade do desvio. A resposta da ação derivativa é proporcional à taxa de variação da variável do processo, aumentando a velocidade de resposta do sistema quando o erro é detectado. Em sistemas com resposta lenta, como o controle de temperatura, a ação derivativa permite antecipar o aumento do erro e agilizar a correção do sistema (OGATA, 2012).

No funcionamento prático, primeiro define-se um objetivo para a variável controlada (*setpoint*) e, a partir disso, calcula-se o erro. É importante destacar que há um erro associado à medição do sensor, que gera atraso na leitura, assim o PID deve ser ajustado para contornar da melhor forma esse problema. Com base no valor de erro, a metodologia PID calcula uma resposta que é enviada ao atuador, responsável por realizar a alteração necessária, impactando

diretamente a variável controlada no processo. O sensor então mede novamente a variável, e o ciclo se repete continuamente, com o objetivo de manter a estabilidade no setpoint. É importante lembrar que o processo não é influenciado apenas pelo atuador, mas também por perturbações externas, conforme ilustrado na Figura 01.

Figura 01 - Fluxograma do controlador PID



Fonte: Adaptado de Campos e Teixeira (2010).


2.1.1 Metodologia de Ziegler-Nichols

A metodologia de Ziegler-Nichols, introduzida em 1942, foi pioneira ao apresentar uma abordagem objetiva e simples para a sintonia de controladores PID. Apesar de antiga, a metodologia abordada ainda continua sendo amplamente utilizada, devido a essa simplicidade. Como base teórica utilizou-se o livro "Controles Típicos de Equipamentos e Processos Industriais" de Mario Cesar e Herbert Teixeira como referência. Ela oferece dois métodos de ajuste para determinar o modelo de um processo SISO (*Single Input, Single Output*), podendo ser aplicada em malha aberta ou fechada.

2.1.1.1 Malha fechada

Nesse caso, com o controlador P em malha fechada, zera-se o termo integral e o derivativo e aumenta-se o ganho proporcional (termo K_p) gradativamente até se obter uma resposta oscilatória com amplitude constante, como mostra a Figura 02, ou seja, procura-se o limiar da instabilidade ou limite da estabilidade. Neste ponto determina-se o ganho último (K) e o período de oscilação (P). O ganho último (K_u) é este ganho do controlador P que gerou uma resposta oscilatória na variável controlada no limite da estabilidade, com um período (P). Se o ganho do controlador for maior que (K), então o sistema será instável (CAMPOS; TEIXEIRA, 2010).

Figura 02 - Exemplo de resposta do processo durante o teste



Fonte: Campos e Teixeira (2010).

Com os valores obtidos de K_u e P_u (que representam a dinâmica do processo), entra-se na Tabela 01 para se obter a sintonia do controlador PID, usando como critério de desempenho uma razão de declínio igual a $1/4$. Apesar de este critério (razão de declínio igual a 4) ter sido considerado como aquele que leva a um desempenho ótimo dos controladores em geral, Ziegler e Nichols alertaram que nem sempre ele deve ser usado (CAMPOS; TEIXEIRA, 2010).

Tabela 01 - Sintonia segundo Ziegler e Nichols, em malha fechada.

Controlador	K_p	T_i	T_d
P	$0.5K_u$	-	-
PI	$0.45K_u$	$P_u/1.2$	-
PID	$0.6K_u$	$P_u/2$	$P_u/8$

Fonte: Adaptado de Campos e Teixeira (2010).

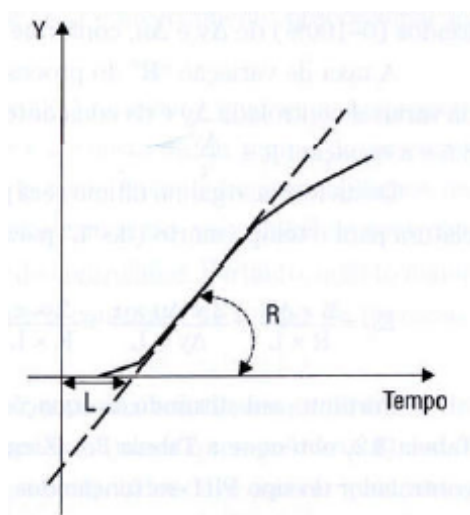
No entanto, na prática, este teste pode levar o processo a variar fora de uma região segura. Não há garantia de que a variável controlada estará entre limites especificados, portanto este teste não é muito utilizado nas plantas industriais (CAMPOS; TEIXEIRA,

2010). Como um segundo método para obter a dinâmica do processo, surge o teste em malha aberta.

2.1.1.2. Malha aberta

Nesse caso, com o controlador em manual, gera-se uma variação em degrau na saída do controlador (Δu) e aguarda-se a estabilização do sistema. Pela resposta do processo (Y) a esta perturbação, calcula-se a taxa de variação " R " e o tempo morto " L ", conforme mostra a Figura 03 (CAMPOS; TEIXEIRA, 2010).

Figura 03 - Resposta do processo em malha aberta



Fonte: Campos e Teixeira (2010).

A vantagem deste método de identificação do modelo é que ele pode ser aplicado a processos integradores, que não apresentam um ganho finito para uma perturbação em degrau. Assim, o ganho último (K_U) e o período último (P_U) podem ser estimados pelas Equações 03 e 04 a seguir.


$$K_U = \frac{2 \times \Delta u}{R \times L} \quad (03)$$

$$P_U = 4 \times L \quad (04)$$

A taxa de variação R do processo acima pode ser obtida a partir da variação da variável controlada ΔY e da constante de tempo do processo (t) (Equação 05), conforme mostra a Figura 04.

$$R = \frac{\Delta Y}{\tau} \quad (05)$$

Figura 04- Resposta do processo de primeira ordem em malha aberta



Fonte: Campos e Teixeira (2010).

Desta forma, substituindo a Equação 03 na Equação 04, o ganho último será dado pelas fórmulas anteriores e mudando a nomenclatura para o tempo morto (de "L" para "Θ"):

$$K_U = \frac{2 \times \Delta u}{R \times L} = \frac{2 \times \Delta u \times \tau}{\Delta Y \times L} = \frac{2 \times \tau}{K \times \Theta} \quad (06)$$

$$P_U = 4 \times L = 4 \times \Theta \quad (07)$$

Portanto, substituindo as equações anteriores do ganho e do período último na Tabela 01, obtém-se a Tabela 02, que mostra a sintonia do controlador do tipo PID em função dos parâmetros de um modelo de primeira ordem.

Tabela 02 - Sintonia segundo Ziegler e Nichols, em malha aberta.

Controlador	Kp	Ti	Td
P	$\tau / (K_x \theta)$	-	-
PI	$0.9 \tau / (K_x \theta)$	$3.33 \times \theta$	-
PID	$1.2 \tau / (K_x \theta)$	$2 \times \theta$	$0.5 \times \theta$


Fonte: Adaptado de Campos e Teixeira (2010).

2.2 Controle MPC

O Controle Preditivo Baseado em Modelo (MPC) consolidou-se como uma das técnicas de controle avançado mais relevantes na engenharia de processos, sendo amplamente utilizado em indústrias modernas, especialmente em sistemas multivariáveis e sujeitos a restrições operacionais. Diferentemente do PID, que atua de forma essencialmente reativa ao

erro, o MPC baseia-se em previsões do comportamento futuro do processo, calculadas a partir de um modelo matemático da planta. Isso permite que as ações de controle sejam determinadas de forma antecipativa e otimizadas a cada instante de amostragem, aumentando a eficiência e a robustez da operação. Dessa forma, o MPC não apenas corrige desvios, mas antecipa distúrbios e evita que eles comprometam a estabilidade do processo.

Figura 05- Funcionamento do MPC



Fonte: MARQUES (2019).

O funcionamento do MPC baseia-se na construção de um modelo de previsão, que pode ser linear ou não linear, responsável por estimar a trajetória futura da variável controlada em função das entradas e do estado atual do processo, como ilustrado na Figura 05. A cada intervalo de amostragem, o controlador resolve um problema de otimização no qual determina a sequência futura de variáveis manipuladas que minimiza uma função objetivo, normalmente composta pelo erro em relação ao *setpoint* e pelo esforço de controle. Apenas a primeira ação calculada é aplicada ao processo, e o problema é reavaliado continuamente à medida que novas medições são incorporadas, garantindo assim a atualização das previsões e a adaptação do controle às condições reais de operação.

As equações que descrevem o MPC podem ser generalizadas pela formulação de um problema de minimização da função objetivo sujeita às restrições do processo. Um exemplo clássico é:

$$J = \sum [y(k+i) - r(k+i)]^2 + \lambda \sum [\Delta u(k+j)]^2 \quad (08)$$

em que N_p é o horizonte de previsão, N_c é o horizonte de controle, $y(k+i)$ são as saídas previstas, $r(k+i)$ é a trajetória de referência, $\Delta u(k+j)$ são as variações da variável manipulada e λ é o fator de ponderação entre desempenho e esforço de controle.

Uma das principais vantagens do MPC é a sua capacidade de lidar com sistemas MIMO (múltiplas entradas e múltiplas saídas) e com restrições explícitas nas variáveis de

processo, o que garante estabilidade e segurança mesmo em condições de operação complexas. Essa característica o torna bastante superior ao PID em sistemas fortemente acoplados, como colunas de destilação, unidades petroquímicas e processos fermentativos.

Por outro lado, o MPC exige maior esforço computacional e depende fortemente da precisão do modelo utilizado. Modelos inadequados ou simplificados podem comprometer a performance do controlador, tornando a sua implementação mais complexa e onerosa do que métodos clássicos. Ainda assim, avanços computacionais e o desenvolvimento de modelos empíricos, incluindo redes neurais artificiais, têm expandido a aplicabilidade do MPC, inclusive em processos não lineares.

O MPC já foi aplicado com sucesso em diversos setores industriais, como na indústria petroquímica, em refinarias de petróleo e em processos de fermentação, sendo considerado uma ferramenta robusta para a indústria 4.0. Sua adoção cresce devido à capacidade de integrar controle e otimização em tempo real, garantindo maior eficiência econômica e energética.

Dentre as diversas variações do controle preditivo, destaca-se o *Dynamic Matrix Control* (DMC), considerado a primeira implementação prática do MPC em escala industrial. Desenvolvido na década de 1970 e aplicado inicialmente pela Shell Oil, o DMC consolidou o controle preditivo como uma estratégia viável, servindo de base para o desenvolvimento de métodos mais avançados, como o *Generalized Predictive Control* (GPC).

Essa metodologia utiliza modelos empíricos, geralmente obtidos a partir de respostas ao degrau do processo, para prever o comportamento futuro da planta. Assim, a partir de dados experimentais, constrói-se uma matriz dinâmica que descreve a relação entre entradas e saídas, permitindo prever a evolução das variáveis controladas diante de diferentes ações de controle. Dessa forma, a saída prevista no horizonte de predição pode ser expressa como:

$$\hat{y}(t + p|t) = \sum_{i=p-m+1}^p g_i X \Delta u(t + p - i) + f(t + p) \quad (09)$$

em que g representa os coeficientes obtidos a partir da resposta ao degrau, Δu são as variações das ações de controle e $f(t+k)$ corresponde à resposta livre do sistema.

Para organizar essas predições de forma matricial, define-se a chamada matriz dinâmica G , composta pelos coeficientes da resposta ao degrau do processo:

Figura 06: Matriz dinâmica G

$$G = \begin{bmatrix} g_1 & 0 & \dots & 0 \\ g_2 & g_1 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ g_m & g_{m-1} & \dots & g_1 \\ \vdots & \vdots & \ddots & \vdots \\ g_p & g_{p-1} & \dots & g_{p-m+1} \end{bmatrix}$$

Fonte: Adaptado de Camacho (2007).

Assim, o modelo preditivo do DMC pode ser escrito de forma compacta como:

$$\hat{y} = Gu + f \quad (10)$$

O princípio central do DMC consiste em calcular, a cada intervalo de amostragem, a sequência de sinais de controle que minimiza uma função objetivo, levando em consideração tanto o erro entre a variável controlada e o *setpoint* quanto às restrições operacionais impostas ao processo. No entanto, apenas a primeira ação calculada é aplicada, e o cálculo é repetido continuamente conforme novas medições são incorporadas. Essa característica confere ao DMC um caráter recursivo e adaptativo, tornando-o adequado para processos com variabilidade e perturbações frequentes.

Essa formulação obtida (Equação 10) evidencia a principal característica do DMC: a predição da saída futura a partir da matriz dinâmica construída com dados experimentais, permitindo que o controlador resolva, a cada instante de amostragem, um problema de otimização que considera tanto as ações de controle quanto restrições operacionais do processo.


Apesar de suas vantagens, como simplicidade conceitual e aplicabilidade em sistemas multivariáveis, o DMC apresenta limitações, especialmente relacionadas à qualidade do modelo obtido e ao custo computacional envolvido. Modelos empíricos podem ser válidos apenas dentro de uma faixa restrita de operação, e a necessidade de resolver problemas de otimização em tempo real pode ser custoso em processos muito complexos.

3. CONTROLE DE PROCESSOS EM BIORREATORES

A fermentação alcoólica é um processo bioquímico fundamental tanto na produção de bebidas (vinho, cerveja, destilados) quanto na fabricação de biocombustíveis, especialmente o etanol, que ocupa posição estratégica na matriz energética brasileira (VENTURINI FILHO, 2010; GONÇALVES; BASSO, 2011). A eficiência e a qualidade do produto dependem de diversos fatores, sendo a temperatura um dos mais críticos. Por se tratar de uma reação exotérmica, a fermentação libera calor, de modo que, sem o devido controle, a temperatura do meio pode subir a níveis que comprometem a atividade das leveduras. Assim, o monitoramento e o ajuste desta variável durante a operação são fundamentais para garantir a atividade ótima dos microrganismos e evitar perdas de rendimento (MENEZES, 1980; LIMA; BASSO; AMORIM, 2001).

Além disso, a Figura 07 ilustra o ciclo integrado completo de uma biorrefinaria, destacando como processos biotecnológicos se inserem em um fluxo sistêmico que conecta biomassa, produção de biocombustíveis, geração de energia, obtenção de biomateriais e rotas de reciclagem. Essa representação reforça a importância do controle adequado para garantir eficiência, sustentabilidade e integração entre as diferentes etapas da cadeia produtiva.

Figura 07 - Ciclo integrado completo de uma biorrefinaria



Fonte: BNDES e CGEE (2008).

As dornas fermentativas, utilizadas em usinas sucroalcooleiras, funcionam como biorreatores industriais, que concentram parte significativa da complexidade do processo produtivo de etanol. Além da temperatura, outras variáveis exercem influência direta na performance do sistema, como pH, concentração de açúcares, taxa de crescimento celular, concentração etanólica e contaminação bacteriana. A faixa ótima de pH, por exemplo, deve estar entre 4,0 e 5,0 para favorecer a levedura e inibir a ação de bactérias, sendo comum o uso

de tratamento ácido para reduzir a carga microbiana no início do ciclo fermentativo (MENEZES, 1980; LIMA; BASSO; AMORIM, 2001).

Quanto à tolerância ao etanol, a levedura *Saccharomyces cerevisiae* cresce adequadamente até concentrações de 9–10% (p:v), apresentando inibição acima desses valores, especialmente em temperaturas elevadas (DORTA, 2006). Esses fatores evidenciam o caráter não linear e multivariável do processo, no qual pequenas variações em uma variável impactam significativamente o sistema como um todo.

Outro desafio operacional é o resfriamento das dornas, necessário para manter as condições adequadas de fermentação. Duas estratégias predominam: a captação direta de água e o uso de torres de resfriamento. No primeiro caso, além dos impactos ambientais e do custo associado às exigências legais (Lei nº 9.433/1997 – Lei das Águas), há a desvantagem da variação da temperatura da água conforme a estação do ano (SILVA; SANTOS, 2015). Já as torres de resfriamento apresentam limitações impostas pela temperatura de bulbo úmido, que no Brasil é de aproximadamente 29°C, restringindo a eficiência do processo de refrigeração. A insuficiência no controle térmico pode levar a falhas na fermentação, aumento da produção de subprodutos indesejáveis e menor rendimento alcoólico.

Para tanto, as indústrias sucroenergéticas tradicionalmente empregam controladores PID no controle da temperatura das dornas. Tais controladores atuam integrados a sistemas de monitoramento, ajustando automaticamente válvulas, bombas ou trocadores de calor para manter a variável dentro de uma faixa adequada. O PID é versátil e relativamente simples de implementar, mas seu ajuste pode ser um desafio em processos fermentativos que apresentam forte acoplamento entre variáveis, atraso de transporte e resposta não linear (CAMPOS; TEIXEIRA, 2010).

Apesar da ampla utilização do PID, a complexidade das dornas fermentativas exige técnicas de controle mais avançadas. Nesse cenário, o MPC surge como uma alternativa a utilizar modelos matemáticos para prever o comportamento futuro do processo, ele permite antecipar desvios e calcular ações de controle otimizadas, levando em consideração múltiplas variáveis manipuladas e restrições operacionais, como limites de temperatura e vazão de resfriamento (CAMACHO; BORDONS, 2004). Assim, enquanto o PID é eficaz no controle de variáveis isoladas, o MPC mostra-se mais adequado para sistemas multivariáveis (MIMO) como os biorreatores fermentativos, onde há forte interdependência entre parâmetros.

Além disso, o processo fermentativo está sujeito à variabilidade biológica, decorrente da oscilação no metabolismo das leveduras e da presença de contaminantes. Essa incerteza torna a modelagem e a identificação matemática do processo mais complexas. Nesse sentido, a integração entre MPC e técnicas de inteligência artificial (IA) se destaca como tendência

emergente. Ferramentas baseadas em redes neurais, algoritmos de *machine learning* e modelos híbridos têm sido estudadas para fornecer previsões mais precisas, melhorar a adaptação em tempo real e identificar padrões em grandes volumes de dados industriais. Tais abordagens têm potencial para reduzir perdas, estabilizar a operação das dornas e aumentar a produtividade global da indústria de etanol, alinhando-se às diretrizes da Indústria 4.0.

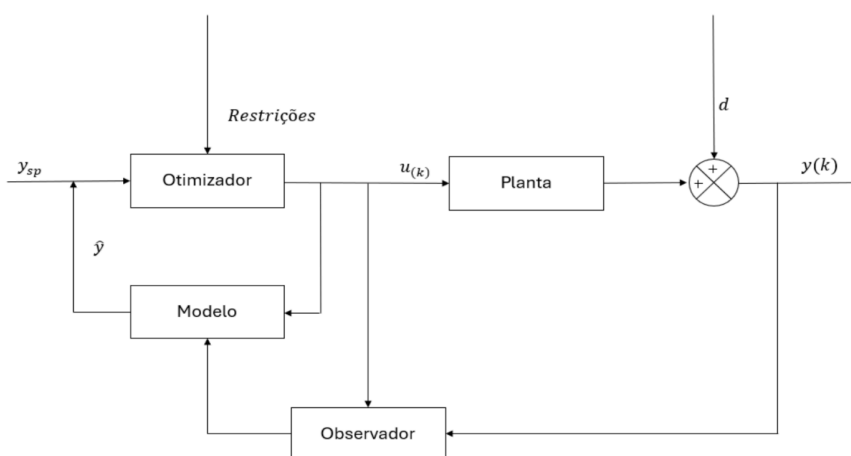
Assim, pode-se dizer que, o controle de biorreatores fermentativos enfrenta três grandes desafios: a não linearidade inerente ao processo, que limita a eficácia de controladores clássicos, a multivariabilidade, que exige métodos capazes de lidar com interações complexas entre variáveis, e a natureza biológica, marcada por incertezas e variabilidade. O uso de PID continua relevante, especialmente em aplicações educacionais e de menor complexidade, mas a evolução para estratégias avançadas como o MPC, em conjunto com IA, representa um caminho vantajoso para tornar a produção de etanol mais eficiente, estável e sustentável.

4. INTELIGÊNCIA ARTIFICIAL NA INDÚSTRIA QUÍMICA

O avanço das técnicas de inteligência artificial tem gerado mudanças significativas na forma como a indústria química aborda problemas de controle e otimização de processos. Controladores clássicos, como o PID, mostraram-se adequados em variáveis isoladas, mas também apresentaram limitações em processos não lineares, multivariáveis e sujeitos a fortes restrições. Nesse contexto, a IA tem sido incorporada de maneira crescente ao MPC, seja para melhorar a representação do processo por meio de modelos orientados a dados, seja para auxiliar na própria lei de controle.

A Figura 08 apresenta a estrutura conceitual de um controlador preditivo baseado em modelo (MPC), destacando os principais blocos funcionais do sistema.

Figura 08 - Estrutura funcional de um controlador preditivo baseado em modelo (MPC)



Fonte: ARAÚJO (2025).

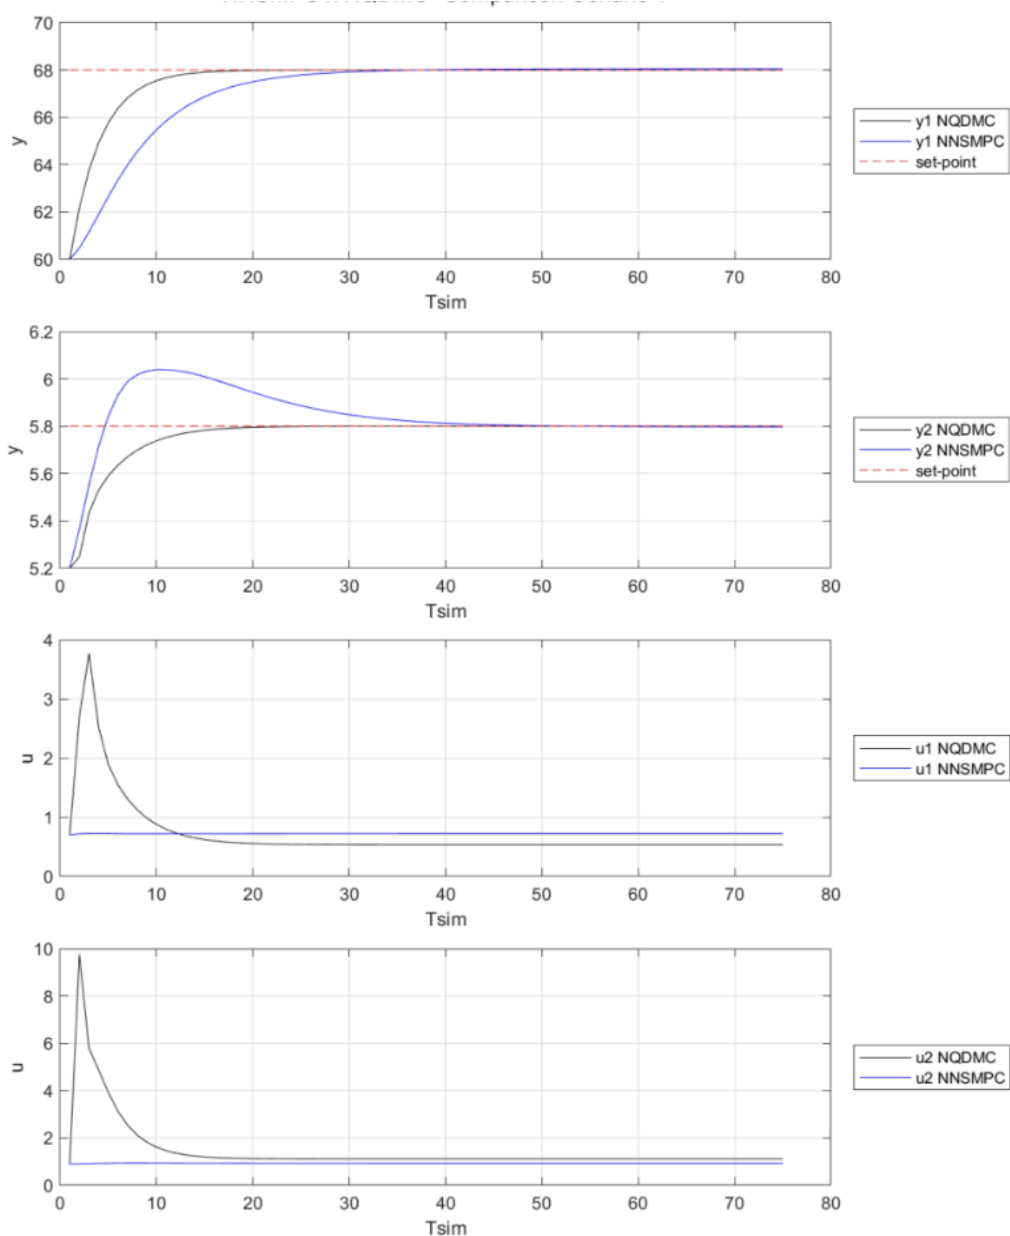
O diagrama mostra como o controlador preditivo utiliza um modelo interno do processo para prever a resposta futura da planta, um otimizador para determinar as ações de controle que respeitam as restrições operacionais e um observador para estimar variáveis de estado não medidas. Essa estrutura forma a base sobre a qual técnicas de inteligência artificial, como redes neurais, podem ser integradas para aprimorar a modelagem e reduzir o custo computacional do controle. Além disso, a IA tem ocupado um papel complementar em camadas adjacentes ao controle, como na implementação de *soft sensors* para variáveis mais complexas de medir em tempo real, na estimação de estados não observáveis e no monitoramento de falhas e anomalias. Essas aplicações têm sido vistas em casos reais, sobretudo em indústrias farmacêuticas e petroquímicas, onde a confiabilidade das medições e a manutenção preditiva representam ganhos diretos de segurança e custo operacional.

O principal ponto de inserção da IA nesse meio é a substituição ou complementação dos modelos tradicionais do MPC por modelos baseados em dados. Entre as abordagens mais utilizadas destacam-se as redes neurais artificiais (ANNs), os processos Gaussianos (GPs) e os modelos híbridos, que combinam primeiros princípios com aprendizado de máquina. Essa estratégia permite capturar não linearidades, mudanças de regime e fenômenos complexos de difícil modelagem.

A exemplo, pode-se citar uma pesquisa desenvolvida na Escola Politécnica da USP, que abordou o uso de controladores preditivos baseados em redes neurais aplicados a diferentes processos químicos. O estudo avaliou alternativas como o *Neural Network Model Predictive Control* (NNMPC), o *Neural Network State Model Predictive Control* (NNSMPC) e variações aproximadas como o *Neural Network State-Space Model MPC* (NNTDMPC). O objetivo central foi analisar se a utilização de redes neurais, seja como modelo interno ou como aproximadores da lei de controle, poderia oferecer desempenho superior ou mais eficiente em comparação a métodos clássicos.

A Figura 09 apresenta os resultados de simulação comparando o desempenho entre o controlador clássico NDQMC e o controlador preditivo baseado em redes neurais (NNSMPC), desenvolvidos no referido estudo.

Figura 09 - Comparação entre o desempenho dos controladores NDQMC e NNSMPC



Fonte: ARAÚJO (2025).

Os gráficos da Figura 09 mostram as respostas das variáveis controladas (y_1 e y_2) e manipuladas (u_1 e u_2) ao longo do tempo. É possível verificar que ambos os controladores atingem o ponto de operação desejado, mas o NNSMPC apresenta uma resposta mais suave e com menor sobressinal, demonstrando maior estabilidade e precisão. Tais resultados reforçam o avanço observado na integração entre controle preditivo e inteligência artificial, campo em que o aprendizado de máquina tem se mostrado especialmente útil na otimização de sistemas complexos e multivariáveis.

Um outro ponto a ser destacado neste trabalho foi a aplicação em processos de referência, como a coluna fracionadora da Shell. Esse caso permitiu avaliar o comportamento

dos controladores em condições realistas, incluindo restrições operacionais e não linearidades.

A coluna fracionadora da Shell é amplamente reconhecida na literatura de controle de processos químicos como um dos principais *benchmarks* experimentais para avaliação e validação de estratégias de controle preditivo, especialmente aquelas baseadas em modelagem não linear e inteligência artificial.

O termo *benchmark* refere-se, nesse contexto, a um modelo de processo padrão de referência, desenvolvido para representar de forma realista o comportamento dinâmico de sistemas industriais complexos. Esses modelos são muito utilizados em casos de estudo comparativos, permitindo a análise sistemática de desempenho, estabilidade e custo computacional de diferentes técnicas de controle sob condições idênticas de operação (DOWNS; VOGEL, 1993).

Já na área de engenharia de controle e otimização de processos, o uso de *benchmarks* têm papel significativo. Ele possibilita reproduzir, em ambiente de simulação, os principais desafios encontrados em plantas industriais reais, tais como: forte acoplamento entre variáveis, restrições operacionais rigorosas, não linearidades significativas e perturbações externas. A escolha da coluna fracionadora da Shell como processo de referência é apropriada por sua dinâmica multivariável complexa e pela presença de múltiplos controladores interdependentes, o que a torna um sistema ideal para testar e validar metodologias de controle avançadas.

A planta consiste em uma coluna de destilação multicomponente, equipada com condensador, refeedor e sistemas de refluxo, representando o fracionamento de uma mistura típica da indústria petroquímica. O condensador, localizado no topo da coluna, é responsável por condensar parcialmente o vapor ascendente, controlando simultaneamente a pressão de topo e a composição do produto condensado. Na base da coluna, o refeedor (*reboiler*) fornece o calor necessário à vaporização parcial da corrente líquida, determinando o perfil de temperatura ao longo da coluna. Além disso, o sistema conta com duas válvulas de refluxo, uma superior e uma intermediária, que ajustam o retorno de líquido aos estágios de separação, permitindo o controle da pureza dos produtos de topo e lateral (*side draw*).

Entre as variáveis manipuladas, destacam-se o refluxo superior e o fluxo de vapor do refeedor, enquanto as variáveis controladas incluem as composições do produto de topo e lateral, além da temperatura no fundo da coluna.

Essas variáveis interagem fortemente entre si, o que caracteriza um problema de controle multivariável acoplado, onde alterações em uma variável podem impactar de maneira não linear o comportamento das demais. Essa característica torna o processo ideal

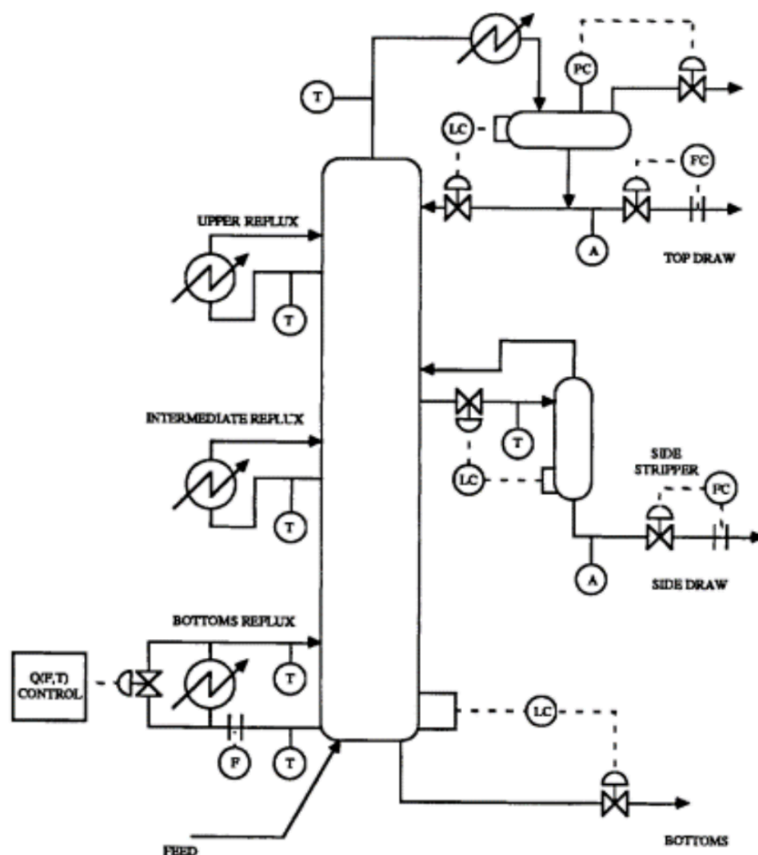
para estudos envolvendo controladores preditivos multivariáveis, já que impõe ao algoritmo o desafio de manter a estabilidade e o desempenho global diante de interações complexas e restrições físicas.

Outro ponto importante é que esse modelo da planta incorpora limites operacionais realistas, como faixas de temperatura, composição e vazão, que refletem as condições industriais típicas de unidades petroquímicas. Assim, os controladores precisam equilibrar o desempenho dinâmico com a segurança operacional, otimizando o processo sem violar restrições críticas.

Por essas razões, a planta tem sido usada em pesquisas nacionais e internacionais que buscam desenvolver e aprimorar controladores preditivos baseados em IA, redes neurais artificiais (ANNs) e modelagem híbrida (ARAÚJO, 2025; DOWNS; VOGEL, 1993). O uso desse *benchmark* permite comparar, de maneira padronizada, o desempenho de estratégias clássicas, como o *Model Predictive Control* (MPC) linear, com abordagens avançadas que utilizam modelos neurais não lineares para previsão e tomada de decisão

A Figura 10 ilustra o diagrama esquemático da coluna fracionadora da Shell.

Figura 10- Diagrama esquemático da coluna fracionadora da Shell



Fonte: ARAÚJO (2025).

O diagrama destaca as principais correntes e instrumentos de controle como válvulas de refluxo, controladores de temperatura e pressão, e o sistema de retirada lateral (*side draw*).

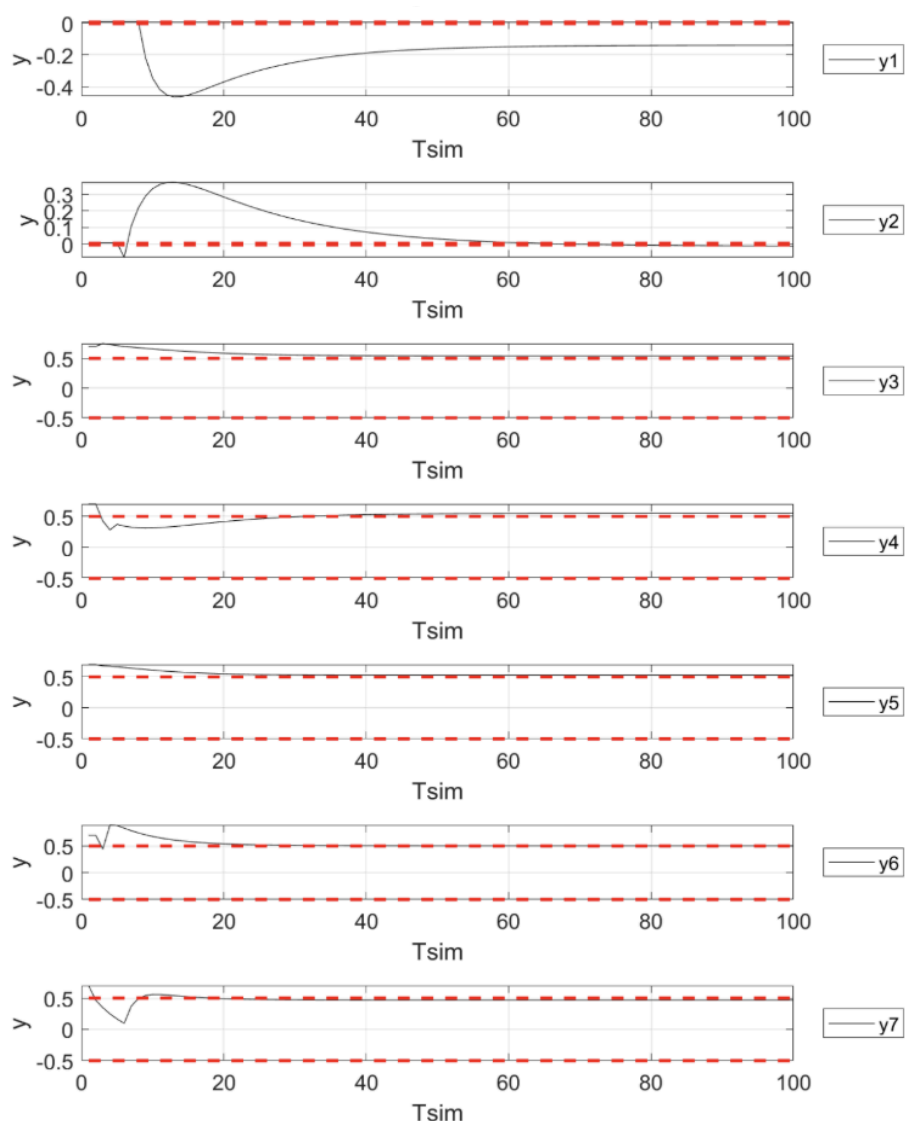
Neste estudo, a escolha da planta da Shell como referência permitiu avaliar o desempenho dos controladores neurais em um ambiente com características típicas de processos industriais reais. Ao utilizar um modelo amplamente validado na literatura, foi possível observar de forma comparativa como a incorporação de redes neurais no controlador preditivo impacta diretamente o comportamento dinâmico do sistema, especialmente em termos de estabilidade, tempo de resposta e custo computacional.

Dessa forma, essa abordagem experimental reforça o papel da IA como uma ferramenta complementar aos métodos clássicos de controle preditivo, uma vez que demonstra, em condições realistas, a capacidade das redes neurais de aprender as não linearidades do processo e de gerar ações de controle mais adaptativas sem necessidade de reformulação matemática completa do modelo fenomenológico.

Contudo, a análise também revela limitações importantes. O estudo destacou que a eficácia dos controladores neurais depende fortemente da região de treinamento da rede. Fora dessa região, surgiram desvios (*offsets*) e perda de robustez, o que evidencia a necessidade de cuidados no planejamento dos dados de treino e validação. Isso reforça a ideia de que a IA pode desempenhar papel de destaque na evolução da área de controle, principalmente ao lidar com não linearidades que, em muitos casos, desafiam a modelagem fenomenológica tradicional. Além disso, a estratégia de aproximar a lei de controle por meio de redes neurais é inovadora e mostra um ganho prático significativo em custo computacional, ponto crítico para a adoção industrial de técnicas avançadas.

A Figura 11 apresenta os resultados da simulação do controlador neural NNTDMPC aplicado à coluna fracionadora da Shell, utilizados para comparar o desempenho das estratégias de controle preditivo baseadas em inteligência artificial.

Figura 11- Respostas simuladas das variáveis controladas (y_1 a y_7) da coluna fracionadora da Shell utilizando o controlador neural NNTDMPC



Fonte: ARAÚJO (2025).

Os gráficos acima exibem as respostas temporais das variáveis de saída da planta simulada (y_1 a y_7), controladas por meio do NNTDMPC. Essas variáveis correspondem, respectivamente, à composição da saída de topo, composição da saída lateral, temperatura de topo, temperatura do refluxo superior, temperatura de retirada lateral, temperatura do refluxo intermediário e temperatura do refluxo de fundo. As linhas tracejadas em vermelho representam os valores de referência (*set-points*), enquanto as linhas pretas indicam as respostas obtidas pelo controlador. Esses resultados evidenciam o potencial das redes neurais em replicar a capacidade de previsão e otimização do MPC clássico, reduzindo o custo computacional ao eliminar a etapa de otimização on-line.

Além disso, a simulação reforça a aplicabilidade da IA em sistemas multivariáveis com forte acoplamento, característica fundamental de processos industriais complexos, como os petroquímicos. Esse tipo de análise gráfica demonstra, de forma quantitativa e visual, o desempenho do controlador proposto em condições realistas.

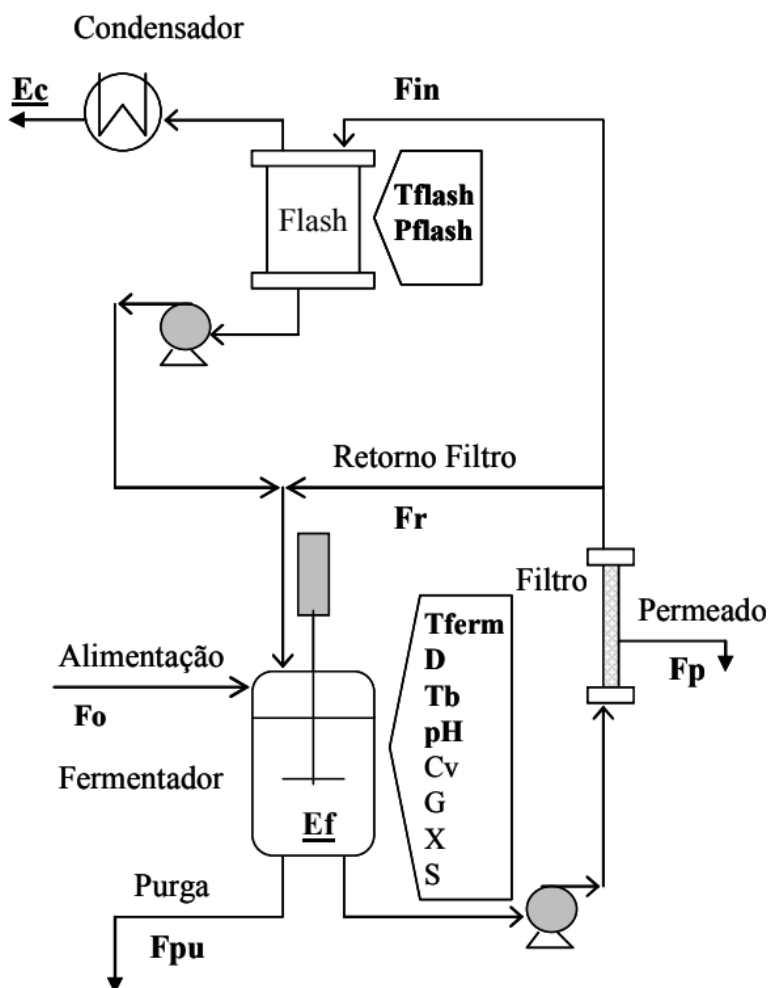
No entanto, há também pontos de atenção e limitações os quais foram supracitados. Essa fragilidade expõe um problema central da aplicação de IA na área de controle: a generalização ainda é limitada, o que restringe a confiabilidade em cenários dinâmicos e sujeitos a incertezas, como é o caso da maioria dos processos industriais. Outro fator limitante é a falta de interpretabilidade das redes neurais, que funcionam como “caixas-pretas”. Em indústrias com alta exigência de segurança e regulamentação, como a petroquímica e a farmacêutica, essa ausência de explicações para as decisões do controlador pode dificultar a sua adoção em larga escala (MOWBRAY et al., 2022).

Ao analisar o papel da inteligência artificial nesse contexto, verifica-se que ela tem avançado justamente nas frentes exploradas pelo estudo: modelagem baseada em dados e aproximação de leis de controle complexas. Nos últimos anos, a literatura científica explorou alternativas como redes neurais profundas, redes recorrentes e processos gaussianos aplicados ao MPC, todos com o objetivo de aumentar a capacidade de previsão e reduzir custos computacionais.

Ademais, uma outra pesquisa, agora desenvolvida pela Universidade Estadual de Campinas (UNICAMP), que tem como tema a “Identificação de processos e controle preditivo com modelo utilizando técnicas de Inteligência Artificial aplicadas a produção de bioetanol” teve enfoque na aplicação de redes neurais artificiais (ANNs) no controle de processos biotecnológicos, mais especificamente em um sistema de fermentação extrativa contínua para a produção de etanol. O estudo parte da constatação de que a fermentação alcoólica é um processo não linear, multivariável e sujeito a restrições, características que dificultam o uso exclusivo de modelos fenomenológicos em controladores preditivos tradicionais, como o DMC ou o MPC.

A Figura 12 apresenta o diagrama esquemático da planta de fermentação extrativa contínua estudada na UNICAMP, utilizada para o desenvolvimento e validação do controlador neural proposto.

Figura 12 - Diagrama esquemático da planta de fermentação extrativa contínua



Fonte: Universidade Estadual de Campinas (UNICAMP). Identificação de processos e controle preditivo com modelo utilizando técnicas de Inteligência Artificial aplicadas à produção de bioetanol., 2012.

O fluxograma mostra as principais unidades que compõem o sistema de produção de etanol, o fermentador (Ef), o tanque flash, o filtro de membrana e o condensador. O processo é caracterizado por ciclos internos de corrente (como o retorno de filtro Fr) e múltiplas variáveis controladas, incluindo temperatura, pH, concentração celular (X) e vazão.

Essa configuração representa fielmente um sistema biotecnológico multivariável e não linear, no qual o comportamento dinâmico é fortemente influenciado por interações entre as variáveis. Por essa razão, o estudo propôs o uso de uma rede neural artificial (ANN) como modelo interno do controlador preditivo não linear (NMPC), capaz de antecipar o comportamento futuro das variáveis e calcular ações de controle otimizadas de forma proativa.

A escolha desse sistema reforça a relevância industrial do estudo, visto que a fermentação extrativa contínua é uma etapa crítica da cadeia de biocombustíveis, e o controle inteligente dessas variáveis impacta diretamente a produtividade e a estabilidade do processo. Nesse contexto, os pesquisadores propuseram a integração de uma rede neural como modelo interno de um controlador preditivo não linear. A rede foi treinada a partir de dados do processo, com o objetivo de prever a evolução das variáveis de interesse em horizontes futuros e permitir que o controlador calculasse ações otimizadas de forma antecipativa. Aspectos importantes para a implementação foram avaliados, como a seleção de variáveis relevantes, a geração de dados experimentais para treinamento e validação e a influência do número de camadas e neurônios sobre a capacidade de generalização do modelo.

Os resultados apresentados indicaram bom desempenho servo e regulatório, em um cenário em que o controlador foi capaz de manter as variáveis críticas do processo dentro de faixas adequadas, mesmo diante de perturbações externas e variações na alimentação. Embora controladores lineares tradicionais, como o PID ou o MPC clássico, também possam garantir estabilidade em condições conhecidas, sua eficiência tende a diminuir quando o sistema apresenta forte não linearidade, acoplamento entre variáveis e restrições operacionais múltiplas.

Nesse contexto, a aplicação da inteligência artificial representa um avanço, pois permite que o modelo preditivo aprenda diretamente o comportamento do processo a partir de dados experimentais, ajustando-se a regiões operacionais complexas onde o modelo fenomenológico é limitado. Essa flexibilidade explica por que o controlador baseado em rede neural apresentou melhor capacidade de compensar distúrbios e adaptar-se a mudanças de regime, vantagens relevantes em processos biotecnológicos, marcados por grande variabilidade e incertezas dinâmicas.

O estudo permite, ainda, a identificação de contribuições relevantes para o campo do controle de processos biotecnológicos. Um dos grandes pontos fortes deste é a escolha do sistema de fermentação extrativa contínua para produção de etanol como objeto de pesquisa. Diferentemente de *benchmarks* químicos mais tradicionais, como colunas de destilação, esse processo está diretamente ligado à realidade da indústria sucroenergética, setor estratégico no Brasil e de grande relevância mundial quando se trata de biocombustíveis renováveis. Assim, a pesquisa avança além do plano metodológico, apresentando forte aplicabilidade prática, uma vez que a fermentação alcoólica constitui uma das etapas mais sensíveis da cadeia produtiva do etanol.

Outro aspecto relevante observado no estudo da UNICAMP está na integração de redes neurais artificiais ao controlador preditivo, explorando a capacidade dessas técnicas de

capturar a não linearidade e a dinâmica multivariável dos processos biotecnológicos. Ao substituir ou complementar o modelo fenomenológico, a rede neural foi capaz de prever com maior precisão a evolução de variáveis críticas, permitindo que o controlador atuasse de forma antecipativa e eficaz. Esse comportamento evidenciou que a inteligência artificial pode, de fato, oferecer ganhos concretos no controle de processos fermentativos complexos.

Entretanto, assim como identificado no estudo da USP, o trabalho também ressaltou limitações estruturais comuns à aplicação de IA em controle de processos. A principal delas é a dependência da qualidade e representatividade dos dados utilizados no treinamento. Em sistemas biotecnológicos, onde há variabilidade natural das matérias-primas, sazonalidade agrícola e risco de contaminações, essa dependência se torna crítica, podendo comprometer a capacidade de generalização das redes neurais e reduzir sua robustez diante de perturbações inesperadas. Essa vulnerabilidade reflete um problema recorrente no uso de IA em bioprocessos: o risco de sobreajuste a condições laboratoriais que não reproduzem a complexidade industrial. Assim, embora os resultados indiquem elevado potencial de melhoria de desempenho, a aplicabilidade em larga escala ainda requer estratégias adicionais de estabilidade, validação e interpretabilidade, de modo a garantir que os controladores inteligentes possam operar com segurança e eficiência em ambientes reais.

Ainda nesse sentido, embora os resultados sejam promissores em ambiente experimental, a transição para usinas reais envolve desafios adicionais, como o custo computacional em tempo real, a necessidade de validação regulatória e a integração com sistemas de automação já existentes. Além disso, compreender como o controlador toma suas decisões ainda é um desafio importante. Por se basearem em redes neurais, é difícil identificar claramente quais variáveis influenciam cada ação de controle. Essa falta de transparência pode gerar dúvidas operacionais e dificultar a inserção da tecnologia em ambientes industriais altamente regulados.

Do ponto de vista da inteligência artificial, a pesquisa discutida acima confirma a tendência de que o futuro do controle de processos biotecnológicos passa por soluções híbridas, que combinem modelos fenomenológicos (baseados em balanços de massa e energia) com modelos orientados a dados (como redes neurais). Essa integração busca aliar o rigor físico-químico à flexibilidade da IA, resultando em modelos mais robustos e generalizáveis. Além disso, abre espaço para o uso de técnicas mais recentes, como redes recorrentes que poderiam capturar de forma ainda mais adequada as dependências temporais características de processos fermentativos, ou ainda métodos de aprendizado por reforço (*Reinforcement Learning*), que vêm sendo investigados para o ajuste on-line de controladores em sistemas complexos.

A partir das análises, observa-se que ambas as abordagens exploram o potencial das redes neurais artificiais para representar a dinâmica de sistemas complexos, substituindo ou complementando modelos fenomenológicos tradicionais. No caso da USP, o foco esteve em processos de natureza determinística e bem modelada, como a coluna fracionadora da Shell, permitindo avaliar o desempenho dos controladores sob condições controladas e com restrições conhecidas. Já o trabalho da UNICAMP apresentou uma aplicação voltada a sistemas biotecnológicos, com características fortemente não lineares e variabilidade biológica, mostrando que a IA também é promissora em processos com maior grau de incerteza.

Essas duas linhas se unem em um ponto central: a IA tem se mostrado eficaz na captura de não linearidades, na previsão de comportamentos dinâmicos e na otimização preditiva. Entretanto, ambas reforçam a dependência crítica da qualidade dos dados e a necessidade de robustez e interpretabilidade dos modelos neurais, desafios que ainda limitam sua aplicação em escala industrial.

Assim, a observação conjunta dos trabalhos demonstra que o Brasil tem acompanhado as tendências internacionais. Essa atuação reforça a inserção das universidades brasileiras na fronteira tecnológica do controle de processos, integrando ciência de dados e engenharia de sistemas.

Complementando essa análise, é importante situar os avanços observados nos estudos nacionais dentro do contexto global. Um exemplo relevante é a revisão publicada por Mowbray et al. (2022) no periódico *Reaction Chemistry & Engineering*, que apresenta uma análise abrangente sobre a inserção da inteligência artificial e do aprendizado de máquina na indústria de processos químicos.

O artigo destaca que, embora muitas vezes as aplicações de *machine learning* sejam ilustradas com exemplos distantes da realidade da engenharia química, o campo vem crescendo e já apresenta resultados concretos em áreas críticas, como monitoramento de falhas, controle preditivo, otimização de processos e implementação de *soft sensors*.

Um dos pontos centrais trazidos pela revisão é que as indústrias químicas, petroquímicas e farmacêuticas têm acumulado grandes bases de dados de operação (*operational historians*), e o grande desafio atual não é apenas armazenar esses dados, mas extrair deles valor para melhorar a segurança, eficiência energética e sustentabilidade. Nesse sentido, modelos orientados a dados, incluindo redes neurais profundas, processos gaussianos e autoencoders, têm sido usados para estimar variáveis de qualidade em tempo real, prever falhas em ativos críticos e até apoiar a implementação de gêmeos digitais (*digital twins*).

Esse contexto dialoga diretamente com os trabalhos discutidos anteriormente. No caso da USP, em que redes neurais foram empregadas para reduzir o custo computacional do MPC clássico, observa-se alinhamento com a tendência apontada na revisão: substituir a otimização tradicional por aproximações baseadas em IA capazes de manter o desempenho e ampliar a aplicabilidade industrial. Já no caso da UNICAMP, a aplicação em processos fermentativos de etanol exemplifica como o uso de modelos híbridos ou totalmente orientados a dados pode ampliar a capacidade de generalização em sistemas altamente não lineares, algo também enfatizado por Mowbray et al. (2022) como campo emergente para a biotecnologia.

Um aspecto notável é que tanto a revisão quanto os trabalhos nacionais apontam para a mesma limitação estrutural: a dependência crítica da qualidade dos dados. A revisão alerta, ainda, que o uso acrítico de técnicas de IA pode levar a correlações óbvias ou até enganosas se não houver conhecimento de processo orientando a análise. Essa observação reforça a necessidade de engenheiros de processos dominarem fundamentos de ciência de dados, ao invés de esperar que cientistas de dados externos compreendam a fundo as complexidades físico-químicas das plantas industriais.

Dessa forma, ao integrar estudos discutidos com a literatura internacional recente, é possível afirmar que a IA aplicada ao controle de processos está em um momento de consolidação potencial, mas ainda dependente de avanços em interpretabilidade, robustez e integração com modelos fenomenológicos. Esse quadro reforça a relevância dos estudos analisados, pois demonstram que universidades brasileiras têm atuado na fronteira dessa área de pesquisa, explorando tanto casos de referência clássicos quanto problemas industriais estratégicos.


5. APLICAÇÃO NA INDÚSTRIA SUCROALCOOLEIRA

O setor sucroalcooleiro brasileiro ocupa posição de destaque mundial tanto pela sua relevância econômica quanto pelo papel estratégico que desempenha na transição para uma matriz energética mais sustentável. O Brasil é o segundo maior produtor de etanol do mundo, sendo responsável por cerca de 28% da produção global (*Renewable Fuels Association 2024*), e detém a maior eficiência produtiva entre os países que utilizam biomassa como fonte primária de energia, como ilustrado na Figura 13. Além do etanol, a indústria da cana-de-açúcar é responsável pela geração de energia elétrica a partir da cogeração com bagaço e palha, consolidando-se como um dos pilares da bioeconomia nacional. A integração entre produção de biocombustíveis, bioenergia e subprodutos de alto valor agregado vem

impulsionando o conceito de biorrefinaria, em que a eficiência operacional e o uso racional de recursos tornam-se fatores decisivos para a competitividade e a sustentabilidade do setor.

Figura 13 - Distribuição da produção global de etanol por região (2024)

Produção Global de Etanol por Região (2024)



Fonte: Adaptado de RENEWABLE FUELS ASSOCIATION (2024).

Nesse sentido, a fermentação alcoólica representa um dos pontos críticos da cadeia produtiva, pois influencia diretamente o rendimento, a qualidade e a estabilidade do processo. As dornas fermentativas, reatores biológicos responsáveis pela conversão da sacarose em etanol, são sistemas complexos, dinâmicos e não lineares. A operação dessas unidades depende de múltiplas variáveis inter-relacionadas, como temperatura, pH, concentração de substrato e biomassa, além de restrições biológicas inerentes à levedura utilizada. Pequenas variações nesses parâmetros podem comprometer a eficiência global da fermentação, aumentar o consumo energético ou gerar subprodutos indesejáveis, como ácidos e aldeídos. Assim, o controle preciso e adaptativo dessas variáveis constitui um desafio técnico para a indústria.

Nas últimas décadas, os avanços em automação e instrumentação permitiram ganhos significativos na condução dos processos fermentativos, mas grande parte das usinas ainda opera com sistemas de controle convencionais, predominantemente baseados em controladores PID e medições *off-line*. Essa limitação impede que o processo seja ajustado de

forma preditiva, dificultando a resposta rápida a perturbações e variações de matéria-prima, fatores frequentes devido à natureza biológica e sazonal da cana-de-açúcar. Nesse contexto, a incorporação de técnicas de inteligência artificial (IA) e controle preditivo surge como uma tendência, capaz de se aliar à modelagem orientada a dados, aprendizado contínuo e tomada de decisão autônoma para aprimorar o desempenho operacional das dornas.

A aplicação da IA na indústria de processos químicos e biotecnológicos têm evoluído, especialmente com o uso de redes neurais artificiais (ANNs), *soft sensors*, modelos híbridos e gêmeos digitais (*digital twins*). Esses recursos vêm sendo empregados para estimar variáveis de difícil medição em tempo real, otimizar estratégias de controle, detectar falhas e prever tendências de operação. Embora amplamente exploradas em setores como o petroquímico e o farmacêutico, essas técnicas ainda encontram espaço para expansão no setor sucroalcooleiro, que possui características peculiares, como a alta variabilidade de insumo, restrições térmicas e forte influência biológica, que tornam a sua aplicação desafiadora, mas potencialmente transformadora.

Diante desse contexto, o objetivo deste tópico é discutir as tendências de aplicação de técnicas de Inteligência Artificial e controle inteligente em dornas fermentativas, com base nas evidências mais recentes e na realidade operacional da indústria sucroalcooleira. Busca-se identificar como essas abordagens podem contribuir de forma prática para o aprimoramento da eficiência, previsibilidade e sustentabilidade dos processos fermentativos. A análise propõe cenários de implementação teórica que conciliam fundamentos científicos consolidados com desafios típicos do ambiente industrial brasileiro, destacando potenciais ganhos em rendimento, estabilidade e otimização do uso de recursos. Dessa forma, pretende-se avaliar o papel estratégico da IA na modernização do controle fermentativo, apontando caminhos viáveis para sua incorporação gradual e sustentável nas usinas de açúcar e álcool.

5.1. Panorama tecnológico atual

A inserção de técnicas IA no controle de processos avançou de forma acelerada, passando de provas de conceito restritas a aplicações industriais integradas que combinam modelagem orientada a dados, instrumentação avançada e camadas supervisórias de decisão (SOUSA, F. J. M., et al. 2023). Três eixos concentram as principais tendências recentes: o uso de IA em controladores preditivos, o desenvolvimento de sensores virtuais e a aplicação de gêmeos digitais como plataformas integradoras.

No controle preditivo, a IA vem sendo utilizada tanto como modelo interno, substituindo ou complementando o modelo fenomenológico por redes neurais, processos gaussianos ou modelos híbridos, quanto como uma forma de aproximar a lei de controle,

reduzindo o custo computacional on-line (ASSIS, A. J. de, et al. 2001). Esse avanço amplia a capacidade de capturar não linearidades, adaptar-se a mudanças de regime e manter a eficiência em sistemas sujeitos a restrições complexas. Pesquisas recentes apontam que a hibridização entre modelos físicos e modelos de aprendizado de máquina tem permitido ganhos em precisão preditiva e estabilidade operacional em processos químicos e biotecnológicos (BUTEAN et al., 2025).

Os *soft sensors* representam uma das aplicações mais consolidadas da IA em indústrias de processo. Esses sensores virtuais utilizam algoritmos de regressão e aprendizado supervisionado (como *Partial Least Squares*, *Random Forests* e redes neurais artificiais) para estimar variáveis de difícil medição direta, como teor alcoólico, concentração celular ou açúcares residuais, com base em variáveis de fácil acesso, como temperatura, pH e vazão (BRUNNER et al., 2021). Agora, em processos fermentativos já apresenta resultados concretos na melhoria da eficiência e detecção precoce de desvios operacionais, sendo considerado um passo fundamental para a futura implementação de controle preditivo baseado em IA (BUTEAN et al., 2025).

Paralelamente, os gêmeos digitais vêm se consolidando como ferramentas integradoras que unem modelagem, controle e análise de dados em uma estrutura dinâmica e conectada ao processo real. Em bioprocessos, o gêmeo digital permite simular cenários de operação, testar estratégias de controle e prever o comportamento futuro de variáveis-chave, sem comprometer a operação física. Essa tecnologia tem se mostrado promissora para conectar modelos híbridos e dados de sensores em tempo real, permitindo tomadas de decisão mais ágeis e precisas. Embora mais explorada em setores como o farmacêutico e o de tratamento de efluentes, sua aplicação em processos de fermentação é considerada uma das principais fronteiras de inovação no controle biotecnológico (OLIVEIRA JUNIOR et al., 2023).

No setor sucroalcooleiro, o avanço da digitalização é perceptível nas etapas de moagem, destilação e cogeração, mas a fermentação alcoólica ainda apresenta lacunas importantes. A variabilidade biológica da matéria-prima (sazonalidade, pureza do caldo, contaminação microbiana), a limitação de medições on-line de variáveis de qualidade (como teor alcoólico e concentração de leveduras) e a ausência de modelos preditivos robustos dificultam o controle em tempo real (BRUNNER et al., 2021). Além disso, as restrições de utilidades e o alto acoplamento entre variáveis tornam o sistema altamente não linear, o que compromete o desempenho de controladores clássicos do tipo PID, ainda predominantes nas usinas.

Nesse cenário, as soluções mais viáveis de curto prazo para adoção na indústria sucroalcooleira incluem: o desenvolvimento de *soft sensors* para estimar variáveis críticas em tempo real; a implementação de algoritmos de detecção de anomalias baseados em *autoencoders* ou PCA para identificação precoce de contaminações; e o uso de controladores preditivos híbridos para otimizar a temperatura e o pH, respeitando restrições térmicas e biológicas (BUTEAN et al., 2025). Essas estratégias estão alinhadas às recomendações da literatura internacional, que apontam essas tecnologias como os principais geradores de valor para bioprocessos na próxima década.

5.2. Justificativa técnica para aplicação em dornas fermentativas

As dornas fermentativas representam uma das etapas mais críticas e complexas da cadeia produtiva do etanol. Nelas ocorre a conversão bioquímica dos açúcares em etanol e CO₂, por ação de leveduras do gênero *Saccharomyces cerevisiae*. Esse processo é caracterizado por não possuir linearidade, acoplamento entre variáveis (como temperatura, pH e teor alcoólico) e restrições operacionais rígidas relacionadas à estabilidade do fermento e à eficiência de conversão (CECCATO-ANTONINI, S. R. 2021).

Do ponto de vista do controle de processos, as dornas fermentativas são sistemas multivariáveis e dinâmicos, frequentemente sujeitos a perturbações externas, como variação da qualidade do caldo, flutuações de temperatura ambiente e contaminações bacterianas, que alteram o balanço metabólico das leveduras. Essas características dificultam a aplicação de controladores lineares convencionais, como o PID, cuja eficiência depende da linearidade do sistema e da constância das condições de operação (BUTEAN et al., 2025).

Além disso, o processo fermentativo impõe restrições termodinâmicas e biológicas que demandam monitoramento contínuo. A temperatura, por exemplo, influencia diretamente a velocidade de reação e a viabilidade celular, mas variações acima de 35 °C podem causar a morte das leveduras, comprometendo o rendimento da reação. De modo similar, o pH precisa ser mantido na faixa de 4,0-5,0 para evitar o crescimento bacteriano, enquanto a concentração de etanol atua como inibidor metabólico, afetando a produtividade do processo (CECCATO-ANTONINI, S. R. 2021).

Esses fatores tornam o controle da fermentação um problema de otimização com múltiplas restrições, cuja solução requer abordagens preditivas e adaptativas. Nesse contexto, a inteligência artificial surge como ferramenta estratégica por sua capacidade de modelar relações não lineares e de aprender padrões de comportamento a partir de dados históricos e operacionais. Segundo estudos recentes publicados em *MDPI Processes*, como os trabalhos de Butean et al. (2025), Escobar et al. (2021) e Silva & Maciel (2020), técnicas como redes

neurais artificiais, processos gaussianos e modelos híbridos têm alcançado grande precisão na estimativa de estados e na implementação de *soft sensors* para processos fermentativos.

A aplicação dessas técnicas pode minimizar alguns dos principais desafios técnicos enfrentados pelas usinas de etanol:

- Variabilidade biológica: a IA pode identificar padrões de adaptação das leveduras ao longo dos ciclos de fermentação, ajustando parâmetros de controle de forma preditiva;
- Medições on-line limitadas: sensores virtuais baseados em redes neurais podem estimar variáveis não medidas diretamente, como teor alcoólico ou concentração de células viáveis, com alta precisão;
- Otimização energética: modelos de aprendizado preditivo permitem antecipar desvios térmicos, ajustando o balanço de calor e o uso de utilidades para reduzir o consumo energético do sistema;
- Prevenção de contaminações: algoritmos de detecção de anomalias baseados em aprendizado não supervisionado podem identificar, precocemente, desvios microbiológicos a partir de dados de condutividade, pH e CO₂ dissolvido.

A combinação de controle preditivo baseado em modelos (MPC) com IA orientada a dados pode, portanto, elevar a robustez e a eficiência operacional das dornas. A integração de *soft sensors*, redes neurais e técnicas de otimização multiobjetivo cria um ambiente de controle mais autônomo, capaz de se ajustar a diferentes cenários de operação sem necessidade de recalibração manual.

5.3 Cenários de aplicação propostos

A partir da revisão bibliográfica e dos estudos analisados anteriormente, é possível propor cenários práticos para a aplicação de técnicas de Inteligência Artificial em dornas fermentativas da indústria sucroalcooleira. Tais cenários buscam trazer, de forma aplicada, o potencial das abordagens orientadas a dados para otimizar o processo de fermentação alcoólica, reduzir perdas e aumentar a previsibilidade operacional.

O primeiro cenário proposto é o controle térmico inteligente, voltado para o ajuste dinâmico da temperatura das dornas. A fermentação alcoólica é um processo fortemente dependente da temperatura, que influencia diretamente o metabolismo das leveduras e, consequentemente, a taxa de conversão de açúcares em etanol. Propõe-se a utilização de controladores preditivos baseados em redes neurais artificiais (*Neural Network Model Predictive Control – NNMPC*), capazes de prever o comportamento térmico futuro do sistema e antecipar ações de controle sobre a vazão de água de refrigeração. Pesquisas recentes demonstram que o uso de modelos neurais reduz significativamente as oscilações térmicas e

antecipa inércias de aquecimento antes que afetem o metabolismo celular. Essa abordagem permitiria um controle mais estável e eficiente, reduzindo o consumo de água e energia térmica, e aumentando a produtividade.

O segundo cenário refere-se à implementação de *soft sensors* para estimativa de variáveis críticas. Muitos parâmetros relevantes ao controle fermentativo, tais como a concentração de células viáveis, teor alcoólico e açúcares residuais, não são medidos em tempo real, o que limita o desempenho do controle. *Soft sensors* baseados em redes neurais profundas e máquinas de vetor de suporte (SVR) têm se mostrado eficientes na estimativa contínua dessas variáveis, mesmo em condições não lineares e dinâmicas (LIMA, M. S. de. 2021). A implementação desse tipo de sensor na indústria permitiria substituir análises laboratoriais demoradas por estimativas instantâneas e integradas ao sistema supervisório (SCADA), fornecendo suporte contínuo à tomada de decisão operacional.

Um terceiro cenário de destaque é a detecção preditiva de contaminações microbianas. Em processos industriais de fermentação, infecções bacterianas representam um dos maiores riscos à estabilidade e ao rendimento alcoólico, podendo causar perdas representativas em uma única batelada. Pode-se sugerir, portanto, o uso de algoritmos de aprendizado não supervisionado, como *autoencoders* e *Isolation Forests*, para identificar padrões anômalos em variáveis de processo, antecipando a ocorrência de contaminações. Estudos, como o Butean et al. (2025), demonstram que tais modelos são capazes de detectar desvios em pH, produção de CO₂ e temperatura com horas de antecedência em relação aos métodos convencionais, permitindo ações corretivas antes que o sistema entre em colapso microbiológico.

O quarto cenário consiste na otimização energética e de utilidades, utilizando algoritmos de aprendizado por reforço (*Reinforcement Learning – RL*) e modelos híbridos físico-dados para coordenar a demanda de utilidades térmicas e elétricas entre as etapas de fermentação e destilação. Segundo o autor, o RL é capaz de encontrar políticas ótimas de operação multivariável sem a necessidade de um modelo exato do processo, aprendendo a equilibrar objetivos concorrentes como eficiência energética, rendimento alcoólico e estabilidade de operação. A aplicação deste em usinas de etanol permitiria reduzir o consumo de vapor e água, além de melhorar a previsibilidade da carga térmica global.

Imaginando-se a integração gradual desses quatro cenários em uma usina sucroalcooleira brasileira de médio porte, isso pode representar um passo importante rumo à digitalização completa do processo fermentativo. Em um contexto industrial típico, a adoção dessas tecnologias pode proporcionar ganhos significativos, como a redução de paradas não programadas, o aumento do rendimento alcoólico e a diminuição do consumo de utilidades

térmicas. Além dos benefícios operacionais, essa modernização contribui para o cumprimento das metas de eficiência energética e sustentabilidade estabelecidas pela bioeconomia nacional e pelas regulamentações ambientais brasileiras.

Entretanto, a implementação dessas soluções envolve desafios importantes, como a necessidade de bases de dados representativas, a resistência operacional à automação e a limitação de interpretabilidade dos modelos de IA. A Tabela 03 a seguir resume os principais riscos associados à adoção dessas tecnologias e as estratégias recomendadas de mitigação.

Tabela 03 – Riscos e estratégias de mitigação na implementação de IA em fermentação alcoólica

Risco	Descrição	Mitigação sugerida
Dados insuficientes	Bases históricas curtas ou inconsistentes reduzem a precisão dos modelos de IA.	Coleta estruturada e pré-processamento contínuo de dados, com implantação gradual.
Resistência operacional	Operadores e supervisores podem não confiar e não compreender sistemas autônomos.	Treinamento técnico, interface explicativa e integração homem-máquina.
Falta de transparência	Dificuldade em compreender as decisões do controlador.	Uso de técnicas de <i>Explainable AI</i> (XAI) e modelos híbridos físico-dados.
Limites físicos de utilidades	Algoritmos podem propor soluções inviáveis fisicamente.	Inclusão de restrições explícitas no modelo e validação em simulações off-line.

Fonte: Autoria própria.

Esses riscos não tornam a adoção das tecnologias inválida, mas evidenciam a importância de uma estratégia gradual e supervisionada, com envolvimento de especialistas e engenheiros de processo na configuração e interpretação dos modelos.

5.4 Tendências futuras e visão estratégica

As tendências emergentes em Inteligência Artificial aplicada à engenharia química indicam um avanço acelerado em direção a sistemas integrados, autônomos e interpretáveis. No contexto da indústria sucroalcooleira, esse movimento converge para a criação de ambientes digitais inteligentes, em que dados, modelos e decisões são integrados de forma contínua e adaptativa.

Uma das tendências mais promissoras é o aprendizado por reforço, que permite que algoritmos “aprendam” a tomar decisões ideais a partir da interação contínua com o processo. Essa abordagem, já consolidada em setores como a petroquímica e o refino, tem sido recentemente aplicada em bioprocessos, possibilitando a otimização de variáveis conflitantes, como rendimento, tempo de fermentação e custo energético, sem necessidade de modelagem explícita (BUTEAN et al., 2025). Em uma usina de etanol, o RL pode ajustar dinamicamente a operação das dornas conforme as condições ambientais e as características do mosto, maximizando o desempenho global do sistema.

Outro avanço relevante é a incorporação de gêmeos digitais em processos biotecnológicos. Tradicionalmente utilizados em plantas petroquímicas e de refino, eles estão sendo adaptados para sistemas biológicos com sucesso crescente (Petrobras 2024). Na fermentação alcoólica, um *digital twin* poderia reproduzir em tempo real o comportamento de cada dorna, permitindo prever desvios e testar estratégias de controle antes de aplicá-las fisicamente. Essa integração entre o mundo real e o virtual possibilita maior confiabilidade, segurança e eficiência operacional.

A questão da interpretabilidade da IA também tem certo destaque, com o surgimento de técnicas de *Explainable Artificial Intelligence* (XAI), voltadas para a compreensão das decisões tomadas pelos modelos de aprendizado de máquina. Isso é importante em processos regulados e de alta responsabilidade técnica, como o setor de biocombustíveis, onde auditorias e rastreabilidade são fundamentais. A adoção de XAI favorece a confiança dos operadores e engenheiros, promovendo maior aceitação industrial das tecnologias inteligentes.

Além disso, a integração entre Internet das Coisas Industrial (IIoT) e *Edge Computing* tende a consolidar a digitalização da produção. A instalação de sensores inteligentes conectados diretamente às dornas permitirá a coleta e o processamento local de dados, reduzindo a latência e aumentando a confiabilidade das decisões. Essa conectividade, aliada a

sistemas de IA embarcados, pode ser uma evolução para tornar a fermentação um processo “inteligente”, em que ela se ajusta autonomamente às condições biológicas e ambientais.

Em uma visão estratégica a curto prazo, considerando um tempo de 5 a 10 anos, pode-se supor que a tendência é que as usinas brasileiras mais competitivas sejam aquelas que incorporarem a IA de forma transversal em toda a cadeia produtiva, desde a fermentação ao tratamento de resíduos. A adoção dessas técnicas e inovações deve tornar possível uma operação autônoma, capaz de se autorregular. Esse avanço, se aplicado no setor sucroalcooleiro brasileiro, o posicionará à frente da bioeconomia global, consolidando-o como um exemplo de biorrefinaria inteligente, sustentável e energeticamente eficiente.

5.5 Análise bibliométrica

Tendo em vista todo estudo e correlações feitas, elaborou-se um fluxograma a partir de dados bibliométricos estruturados em duas planilhas no formato CSV, presentes no APÊNDICE A, uma contendo os nós (*nodes.csv*) e outra as arestas (*edges.csv*), e posterior visualização no *software Cytoscape*.

5.5.1. Metodologia aplicada

A metodologia adotada para a construção deste baseou-se em técnicas de análise de coocorrência de termos e visualização de redes semânticas. O procedimento foi estruturado em etapas sequenciais, de modo a garantir reprodutibilidade, consistência dos dados e clareza na interpretação dos resultados.

Inicialmente, definiu-se o escopo temático do estudo, abrangendo os eixos de controle de processos, inteligência artificial e bioprocessos, com foco em aplicações industriais e energéticas. A partir desse recorte, realizou-se a coleta de registros bibliográficos em bases de dados indexadas, restringindo-se a artigos científicos recentes. Os registros foram exportados contendo informações textuais relevantes, tais como títulos, resumos e palavras-chave.

Na sequência, os dados textuais extraídos passaram por um processo de pré-processamento e normalização dos termos, que incluiu a remoção de acentos, a padronização de letras maiúsculas e minúsculas, a correção de variações ortográficas e a fusão de sinônimos ou termos semanticamente equivalentes. Essa etapa foi necessária para reduzir redundâncias, evitar a fragmentação conceitual e aumentar a consistência das relações de coocorrência entre os termos analisados.

Assim, com o vocabulário consolidado, os artigos científicos foram considerados como unidades de análise, e realizou-se a contabilização da frequência de ocorrência de cada termo ao longo do conjunto de documentos. A partir dessa contagem, elaborou-se a planilha *nodes.csv*, contendo as colunas *Id*, *Label*, *Occurrences* e *Cluster*. O campo *Occurrences* representa a frequência de cada termo na base analisada, enquanto o campo *Cluster* foi

utilizado para agrupar termos semanticamente correlatos, como conceitos técnicos, pedagógicos e analíticos.

Paralelamente, foi construída a planilha *edges.csv*, destinada à representação das relações entre os termos. Essa planilha contém as colunas *Source*, *Target* e *Weight*, em que cada linha representa uma ligação entre dois termos que coocorrem em um ou mais artigos científicos. O peso das arestas (*Weight*) foi calculado com base na força de associação entre os termos, considerando a recorrência conjunta nos documentos e reduzindo o viés associado a termos frequentes na literatura.

Após a preparação das planilhas, os arquivos *nodes.csv* e *edges.csv* foram importados no *software Cytoscape*. O campo *Id* da planilha de “nós” foi utilizado como chave de identificação dos vértices da rede, enquanto as colunas *Source* e *Target* da planilha de arestas foram definidas como conexões de origem e destino. Para a disposição espacial da rede, aplicou-se o algoritmo de *layout Prefuse Force Directed*, que organiza os nós de forma que termos com maior intensidade de conexão se aproximem, enquanto comunidades menos correlatas se afastam.

Por fim, realizou-se a estilização gráfica do fluxograma por meio de mapeamentos visuais baseados nos atributos dos nós e das arestas, incluindo ajustes de tamanho, transparência e simplificação de rótulos, com o objetivo de aprimorar a legibilidade da representação sem comprometer a integridade dos dados. O fluxograma resultante, apresentado na Figura 14, permitiu a identificação de comunidades temáticas coerentes e interconectadas, servindo como base para a análise das tendências científicas e tecnológicas discutidas neste trabalho.

5.5.2. Análise de correlações

O mapa evidenciou ainda que o núcleo técnico formado por conceitos como *Artificial Intelligence*, *Machine Learning*, *Deep Learning* e *Model Predictive Control (MPC)* ocupa posição central na rede, funcionando como “elo” entre os *clusters* de controle de processos, bioprocessos e energia sustentável. Essa centralidade sugere que a literatura atual reconhece a IA como um elemento transversal, capaz de integrar metodologias consolidadas de automação com abordagens orientadas a dados, ampliando significativamente a capacidade de modelagem, previsão e tomada de decisão em sistemas industriais complexos.

Além disso, observa-se uma forte conexão entre os conceitos ligados a bioprocessos, como *Bioreactor*, e aqueles relacionados à transição energética sustentável, como *Renewable energy*. Essa integração reforça que a modernização dos bioprocessos, impulsionada por técnicas avançadas de controle e IA, desempenha papel estratégico na produção de biocombustíveis e na melhoria da eficiência energética. Assim, o fluxograma demonstra que

e técnicas de aprendizado de máquina tende a ser o caminho mais promissor para aplicações industriais.

Por fim, buscou-se reforçar que a aplicação da IA em processos como a fermentação no setor sucroalcooleiro representa uma oportunidade de inovação, capaz de elevar a produtividade, otimizar recursos e impulsionar a transição para sistemas mais inteligentes e sustentáveis. Assim, conclui-se que a integração entre engenharia de processos e inteligência artificial constitui um avanço estratégico para o futuro da indústria química brasileira.

7. REFERÊNCIAS BIBLIOGRÁFICAS

- ALMEIDA, L. P. *Avaliação da transferência de calor em fermentações alcoólicas convencional e extrativa*. 2019. Dissertação (Mestrado em Engenharia Química) — Universidade Federal de São Carlos, São Carlos, 2019.
- ASSIS, A. J. de et al. *Identificação e controle de processos não lineares utilizando redes neurais artificiais*. 2001. 189 f. Tese (Doutorado em Engenharia Química) — Universidade Estadual de Campinas, Faculdade de Engenharia Química, Campinas, 2001.
- BOZA CONDORENA, E. G. *Integração de controle preditivo com inteligência artificial na produção de bioetanol*. 2012. Tese (Doutorado em Engenharia Química) — Faculdade de Engenharia Química, Universidade Estadual de Campinas, Campinas, 2012.
- BRUNNER, V.; SIEGL, M.; GEIER, D.; BECKER, T. Challenges in the development of soft sensors for bioprocesses: a critical review. *Frontiers in Bioengineering and Biotechnology*, v. 9, 2021. DOI: 10.3389/fbioe.2021.722202.
- BUTEAN, A.; CUTEAN, I.; BARBERO, R.; ENRIQUEZ, J.; MATEI, A. A review of artificial intelligence applications for biorefineries and bioprocessing: from data-driven processes to optimization strategies and real-time control. *Processes*, Basel, v. 13, n. 8, p. 2544, 2025. DOI: 10.3390/pr13082544.
- CAMPOS, M. M.; TEIXEIRA, H. C. G. *Controles típicos de equipamentos e processos industriais*. 2. ed. São Paulo: Edgard Blücher, 2010.
- CECCATO-ANTONINI, S. R. *Microbiologia da fermentação etanólica: fundamentos, avanços e perspectivas*. São Paulo: Edgard Blücher, 2021.
- COLOGNI, M. A. *Estudo e avaliação de metodologias de auto-sintonia de controladores PID visando uma implementação em controlador industrial*. 2008. Dissertação — Universidade Federal de Santa Catarina, Florianópolis, 2008.
- CYTOSCAPE. *Cytoscape: an open source platform for complex network analysis and visualization*. Disponível em: <https://cytoscape.org/>. Acesso em: 29 out. 2025.
- DORTA, C. et al. Synergism among lactic acid, sulfite, pH and ethanol in alcoholic fermentation of *Saccharomyces cerevisiae* (PE-2 and M-26). *World Journal of Microbiology and Biotechnology*, v. 22, n. 2, p. 177–182, 2006.
- GARCÍA, C.; ODLOAK, D.; CAMACHO, E. F. *Model Predictive Control in the Process Industry*. 2. ed. Berlin: Springer, 2019. DOI: 10.1007/978-3-662-57838-4.
- GONÇALVES, A. R.; BASSO, L. C. Produção de etanol de cana-de-açúcar: impacto energético e ambiental. *Agroenergia em Foco*, v. 8, p. 12–17, 2011.

JONG, E. de; JUNGMEIER, G. *Biorefinery Concepts in Comparison to Petrochemical Refineries*. Amsterdam: Elsevier B.V., 2015.

LIMA, M. S. de. *Extração de características representativas de movimentos de cabeça para estimativa automática contínua de dor em humanos*. 2021. 104 f. Dissertação (Mestrado em Engenharia Elétrica e de Computação) — Universidade Federal do Rio Grande do Norte, Natal, 2021.

LIMA, U. A.; BASSO, L. C.; AMORIM, H. V. Processos fermentativos e enzimáticos. In: LIMA, U. A. (Coord.). *Biotecnologia Industrial: Processos Fermentativos e Enzimáticos*. São Paulo: Edgard Blücher, 2001. p. 1–43. (Biotecnologia Industrial, v. 3).

MENEZES, T. J. B. *Etanol, o combustível do Brasil*. São Paulo: Editora Agronômica Ceres Ltda., 1980.

MOWBRAY, M. Machine learning and artificial intelligence in the chemical process industries: A review. *Reaction Chemistry & Engineering*, v. 7, n. 10, p. 2045–2062, 2022. DOI: 10.1039/D2RE00234B.

OGATA, K. *Engenharia de Controle Moderno*. 5. ed. Rio de Janeiro: Pearson Prentice Hall, 2012.

OLIVEIRA, A. D. S.; VON SPERLING, M. Impacto ambiental da aplicação de vinhaça no solo: uma revisão. *Engenharia Sanitária e Ambiental*, v. 13, n. 2, p. 221–232, 2008.

OLIVEIRA JUNIOR, A. A. de et al. *A importância dos softwares de simulação dentro da Indústria 4.0: uma análise da inserção do Digital Twin nos contextos industriais*. 2023. Monografia (Graduação em Engenharia de Produção) — Universidade Federal de Ouro Preto, Ouro Preto, 2023. Acesso em: 09 de outubro de 2025.

PETROBRAS. *Digital Twins na Petrobras: como criamos gêmeos digitais para impulsionar a eficiência operacional*. Nossa Energia, 2024. Disponível em: <https://nossaenergia.petrobras.com.br/w/inovacao/digital-twins-na-petrobras-impulsionam-eficiencia-operacional-1-1>. Acesso em: 13 de outubro de 2025.

SILVA, J. B.; SANTOS, L. M. Eficiência energética em processos de fermentação: métodos de resfriamento de mosto. *Revista Brasileira de Engenharia Agrícola e Ambiental*, v. 19, n. 3, p. 210–217, 2015.

SILVA JUNIOR, F. G. da. Biorrefinaria: conceito aplicável ao setor florestal. *Scientia Agrícola*, Piracicaba, v. 8, n. 6, p. 45–49, 2008.

SILVA, R. G. et al. *Utilização de Redes Neurais Artificiais e Técnica SHAP para Predição do Teor de Sólidos Totais durante a Secagem de Lodo Biológico de uma Fábrica de Celulose Kraft*. João Monlevade: Universidade Federal de Ouro Preto, 2024. Disponível em:

https://monografias.ufop.br/bitstream/35400000/6916/2/MONOGRAFIA_Utiliza%C3%A7%C3%A3oModelagemPreditiva.pdf. Acesso em: 28 de outubro de 2025.

SOUSA, F. J. M. et al. Modelos de Sistemas de Supervisão na Indústria 4.0. Models of Supervision Systems in Industry 4.0. *RIPE*, Brasília, v. 9, n. 1, p. 27–48, 2023.

APÊNDICE A - Planilhas

As planilhas utilizadas para a construção do fluxograma de análise bibliométrica, cujas fotos podem ser observadas abaixo, podem ser acessadas pelo *link*: [CytoScape](#)

Figura A.1. Planilha *codes* - Análise bibliométrica

id	label	ocurrences	cluster
PC	Process control	80	1
PO	Process optimization	70	1
IPC	Industrial process control	45	1
ADC	Advanced process control	55	1
PIDC	PID control	50	1
MPC	Model Predictive Control (MPC)	90	1
DMC	Dynamic Matrix Control (DMC)	35	1
CE	Control engineering	85	1
AI	Artificial Intelligence (AI)	140	2
ML	Machine Learning (ML)	130	2
ANN	Neural Networks (ANN)	90	2
DP	Deep Learning	85	2
DPM	Data-driven modeling	60	2
IC	Intelligent control	65	2
HM	Hybrid models	40	2
DT	Digital twins	55	2
BIOREACTOR	Bioreactor	70	3
FERMENTATION	Fermentation	75	3
FERMENTATIVE	Fermentative process	30	3
AF	Alcoholic fermentation	25	3
EP	Ethanol production	80	3
SC	Saccharomyces cerevisiae	45	3
SI	Sugarcane industry	40	3
BIOC	Bioprocess control	55	3
BIOOP	Bioprocess optimization	50	3
BIOFUELS	Biofuels	60	4
RE	Renewable energy	100	4
ET	Energy transition	65	4
SP	Sustainable production	55	4
SE	Sugarcane ethanol	50	4

Fonte: Autoria própria.

Figura A.2 - Planilhas *edges* - Análise bibliométrica

Source	Target	Weight
MPC	AI	9
MPC	ML	8
CE	AI	6
PC	AI	6
CE	ML	6
PC	ML	6
PO	AI	6
PO	ML	6
ADC	AI	5
PIDC	AI	5
IPC	AI	5
ADC	ML	5
PIDC	ML	5
MPC	ANN	5
IPC	ML	5
MPC	DP	5
DMC	AI	5
CE	ANN	5
MPC	BIOC	7
MPC	EP	5
MPC	FERMENTATION	5
CE	EP	5
PC	EP	5
MPC	BIOREACTOR	5
CE	FERMENTATION	5
PC	FERMENTATION	5
CE	BIOREACTOR	5
PC	BIOREACTOR	5
PO	EP	5
PO	FERMENTATION	5
PO	BIOREACTOR	4
MPC	BIOOP	4
MPC	RE	5
CE	RE	5
PC	RE	5
PO	RE	5
ADC	RE	5
MPC	ET	5
PIDC	RE	5
MPC	BIOFUELS	5
CE	ET	5
PC	ET	5
AI	EP	6
AI	FERMENTATION	6
AI	BIOREACTOR	6
ML	EP	6
ML	FERMENTATION	6
ML	BIOREACTOR	6
AI	BIOC	6
AI	BIOOP	5

Fonte: Autoria própria.