



UNIVERSIDADE ESTADUAL DE CAMPINAS

Faculdade de Engenharia Química

FELIPI LUIZ DE ASSUNÇÃO BEZERRA

DESENVOLVIMENTO DE UM CONTROLE DISTRIBUÍDO PREDITIVO BASEADO
EM MODELO NEURAL PARA UMA UNIDADE DE PRODUÇÃO DE ETANOL DE
SEGUNDA GERAÇÃO

CAMPINAS
2019

FELIPI LUIZ DE ASSUNÇÃO BEZERRA

DESENVOLVIMENTO DE UM CONTROLE DISTRIBUÍDO PREDITIVO BASEADO EM
MODELO NEURAL PARA UMA UNIDADE DE PRODUÇÃO DE ETANOL DE SEGUNDA
GERAÇÃO

*Tese apresentada à Faculdade de
Engenharia Química da Universidade
Estadual de Campinas como parte dos
requisitos exigidos para a obtenção do título
de Doutor em ENGENHARIA QUÍMICA,*

Orientador: RUBENS MACIEL FILHO

ESTE TRABALHO CORRESPONDE À
VERSÃO FINAL DA TESE
DEFENDIDA PELO ALUNO FELIPI
LUIZ DE ASSUNÇÃO BEZERRA, E
ORIENTADA PELO PROF. DR.
RUBENS MACIEL FILHO

CAMPINAS
2019

Ficha catalográfica
Universidade Estadual de Campinas
Biblioteca da Área de Engenharia e Arquitetura
Rose Meire da Silva - CRB 8/5974

B469d Bezerra, Felipi Luiz de Assunção, 1990-
Desenvolvimento de um controle distribuído preditivo baseado em modelo neural para uma unidade de produção de etanol de segunda geração / Felipi Luiz de Assunção Bezerra. – Campinas, SP : [s.n.], 2019.

Orientador: Rubens Maciel Filho.
Tese (doutorado) – Universidade Estadual de Campinas, Faculdade de Engenharia Química.

1. Controle preditivo. 2. Etanol 2G. 3. Redes neurais artificiais. 4. Bioetanol. I. Maciel Filho, Rubens, 1958-. II. Universidade Estadual de Campinas. Faculdade de Engenharia Química. III. Título.

Informações para Biblioteca Digital

Título em outro idioma: Development of a neural model based predictive distributed control for a second generation ethanol production plant

Palavras-chave em inglês:

Predictive control

Ethanol 2G

Artificial Neural Networks

Bioethanol

Área de concentração: Engenharia Química

Titulação: Doutor em Engenharia Química

Banca examinadora:

Rubens Maciel Filho

Arioston Araújo de Moraes Júnior

Eduardo Coselli Vasco de Toledo

Leonardo Vasconcelos Fregolente

Adriano Pinto Mariano

Data de defesa: 07-05-2019

Programa de Pós-Graduação: Engenharia Química

Identificação e informações acadêmicas do(a) aluno(a)

- ORCID do autor: <https://orcid.org/0000-0002-4292-5410>

- Currículo Lattes do autor: <http://lattes.cnpq.br/8529742705597350>

Folha de Aprovação da Defesa de Tese de Doutorado defendida por Felipi Luiz de Assunção Bezerra aprovada em 07 de maio de 2019 pela banca examinadora constituída pelos seguintes doutores:

Prof. Dr. Rubens Maciel Filho (Presidente e Orientador)

FEQ / UNICAMP

Prof. Dr. Arioston Araújo de Moraes Júnior

Centro de Tecnologia da Universidade Federal da Paraíba

Dr. Eduardo Coselli Vasco de Toledo

PETROBRÁS – Petróleo Brasileiro S/A

Prof. Dr. Leonardo Vasconcelos Fregolente

FEQ / UNICAMP

Prof. Dr. Adriano Pinto Mariano

FEQ / UNICAMP

ATA da Defesa com as respectivas assinaturas dos membros encontra-se no SIGA/Sistema de Fluxo de Dissertação/Tese e na Secretaria do Programa da Unidade.

RESUMO:

Nos últimos anos, verifica-se um crescente interesse em fontes alternativas de combustíveis e na utilização das fontes de energia renováveis. Esse é o caso do etanol celulósico que pode ser produzido a partir de resíduos da produção agrícola e outros tipos de biomassa. No Brasil, esse processo poderia aumentar significativamente a produção de etanol na indústria de cana-de-açúcar, fazendo uso do bagaço de cana de açúcar já disponível na área de produção das unidades de primeira geração (aquelas que fermentam o caldo da cana). No entanto, processos como a fermentação e a destilação têm uma dificuldade inerente na medição e controle das variáveis em tempo real, que são necessários para possibilitar a operação em alto nível de desempenho, como aquelas acopladas com otimização em tempo real. Uma estratégia de controle distribuído pode trazer benefícios à operação industrial, já que este além de possibilitar a otimização local de cada unidade, também viabiliza a otimização global do processo. Dessa forma, esse trabalho propõe a aplicação e a análise de uma estratégia de controle distribuído preditivo baseado em modelo neural (DMPC), para uma unidade produtiva de etanol (através dos processos de fermentação e destilação). Modelos baseados em redes neurais foram treinados para a caracterização de cada operação de forma a atuarem como modelo de predição do controlador. A estratégia implementada foi comparada com as configurações de controle convencionais *feedback* (ações de controle Proporcional-Integral-Derivativo (PID)) e preditivo baseado em modelo (MPC), onde verificou-se um melhor desempenho do DMPC quando analisados os parâmetros das respostas transiente do processo frente aos distúrbios inseridos.

Palavras-chave: Controle preditivo, Etanol 2G, Redes neurais artificiais, Bioetanol.

ABSTRACT

In recent years there has been a growing interest in alternative sources of fuel and in the use of renewable energy sources. This is the case of cellulosic ethanol that can be produced from agricultural production residues and other types of biomass. In Brazil, this process could significantly increase ethanol production in the sugarcane industry, making use of the sugarcane bagasse already available in the production area of the first generation units (those that ferment the sugarcane juice). However, processes such as fermentation and distillation have an inherent difficulty in measuring and controlling real-time variables, which are required to enable high-level operation, such as those coupled with real-time optimization. A distributed control strategy can bring benefits to the industrial operation, since this besides allowing the local optimization of each operational unit, also makes possible the global optimization of the process. Thus, this work proposes the application and analysis of a predictive distributed control strategy based on neural model (DMPC), for an ethanol production unit (including the fermentation and distillation process). Models based on neural networks were trained to characterize each operation in order to act as a predictor model of the controller. The implemented strategy was compared to the conventional control configurations (Proportional-Integral-Derivative (PID) control actions) and predictive model-based (MPC), where a better performance of the DMPC was verified when the parameters of the transient responses of the process in the face of the disturbances.

Keywords: Predictive control, Ethanol 2G, Artificial Neural Networks, Bioethanol.

Lista de Ilustrações

Figura 1: Esquema do funcionamento do controle preditivo.	18
Figura 2: Configuração do controlador MPC convencional para dois sistemas.....	19
Figura 3: Configuração do controlador DMPC para dois sistemas.	19
Figura 4: Estrutura de um neurônio artificial. Fonte: (AGATONOVIC-KUSTRIN; BERESFORD, 2000).	20
Figura 5: Rede Feedforward. Fonte:(AGATONOVIC-KUSTRIN; BERESFORD, 2000).	21
Figura 6: Rede Feedback. Fonte: (AGATONOVIC-KUSTRIN; BERESFORD, 2000).....	22
Figura 7: Fluxograma de uma unidade de produção integrada de etanol de primeira e segunda geração a partir da cana de açúcar. Fonte: adaptação de DIAS et al. (2013).	23
Figura 8: Processo de fermentação contínua com reciclo de células.	24
Figura 9: Esquema das correntes do reator.....	27
Figura 10: Perturbação da taxa de reciclo e na vazão de alimentação.	29
Figura 11: Perturbação na variável distúrbio do processo fermentativo S_0	30
Figura 12: Processo de destilação binária.....	32
Figura 13: Efeito da razão de refluxo sobre a variável manipulada.	37
Figura 14: Efeito da vazão molar de alimentação de vapor no refeedor sobre a variável manipulada.	37
Figura 15: Perturbação degrau na vazão de destilado da coluna 1 (a) e seu efeito sobre a vazão do destilado na coluna 2 (b).....	38
Figura 16: Efeito da mudança da vazão de destilado sobre a destilação 1 (a) e sobre a destilação 2 (b).	38
Figura 17: Esquema de rede neural do processo fermentativo.	42
Figura 18: mudanças randômicas na taxa de reciclo (Tr).	43
Figura 19: mudanças randômicas na concentração de substrato de entrada (S_0).....	43
Figura 20: Saída P resultante das mudanças em S_0 e Tr	44
Figura 21: MSE para diferentes números de neurônios na camada intermediária.	44
Figura 22: Simulação recursiva para a análise do modelo neural da fermentação.....	45
Figura 23: Esquema de funcionamento do controle preditivo baseado em modelo.	46
Figura 24: Resposta do sistema (a) e ação de controle na taxa de refluxo (b) para diferentes valores de horizonte de predição (N_y).	47
Figura 25: Efeito do horizonte de predição no controle MPC da fermentação.	48
Figura 26: Resposta do sistema (a) e ação de controle na taxa de refluxo (b) para diferentes intervalos de discretização na ação do controlador.	49
Figura 27: Determinação do ganho crítico do processo fermentativo.....	51
Figura 28: Comparação entre o controle MPC e PID para o processo fermentativo com problema servo.	52

Figura 29: Comparação entre o controle MPC e PID para o processo fermentativo para o problema regulador.....	52
Figura 30: perturbações randômicas na razão de refluxo para a destilação 1	56
Figura 31: Variações da fração de etanol na alimentação da destilação 1.	56
Figura 32: Variação na vazão de alimentação de destilação 2.	57
Figura 33: Resposta do sistema na fração de etanol de saída às perturbações randômicas.....	57
Figura 34: perturbações randômicas na razão de refluxo para a destilação 2.	57
Figura 35: Variações da fração de etanol na alimentação da destilação 2.	58
Figura 36: Variação na vazão de alimentação de destilação 2.	58
Figura 37: Resposta do sistema na fração de etanol de saída às perturbações randômicas.....	58
Figura 38: Relação entre o número de neurônios e MSE para a destilação 1 (a) e 2 (b).	59
Figura 39: Simulação recursiva para a destilação 1	60
Figura 40: Simulação recursiva para a destilação 2	60
Figura 41: Efeito do horizonte de predição sobre a destilação 1.....	61
Figura 42: Efeito da do horizonte de controle sobre a destilação 1 (a) e sua respectiva ação de controle (b).	62
Figura 43: Efeito de diferentes valores de discretização sobre a dinâmica da destilação 1	62
Figura 44: Ação de controle sobre a variável manipulada para diferentes valores de discretização.	63
Figura 45: Comparação do controle PID e MPC para o problema servo na destilação 1.	64
Figura 46: Comparação do controle PID e MPC para o problema servo na destilação 2.	64
Figura 47: Comparação do controle PID e MPC para o problema regulador na destilação 1.....	64
Figura 48: Comparação do controle PID e MPC para o problema regulador na destilação 2.....	65
Figura 49: Configuração do controlador DMPC para a planta.....	66
Figura 50: Efeito da perturbação em S_0 sobre a fermentação.....	67
Figura 51: Efeito da perturbação em S_0 sobre a destilação 1.....	67
Figura 52: Efeito da perturbação em S_0 sobre a destilação 2.....	67
Figura 53: Efeito da perturbação em Tr sobre a fermentação.....	68
Figura 54: Efeito da perturbação em Tr sobre a destilação 1.	68
Figura 55: Efeito da perturbação em Tr sobre a destilação 2.	68
Figura 56: Esquema de funcionamento do controlador DMPC.	69
Figura 57: Mudança no set-point da fermentação e atuação do controle MPC.....	70
Figura 58: Controle PID, MPC e DMPC para a destilação 1.	70
Figura 59: Ação de controle MPC sobre a destilação 1.	71
Figura 60: Atuação do controle DMPC na destilação 2.	71
Figura 61: Mudança no set-point da fermentação e ação do controle MPC.....	72
Figura 62: Problema servo da destilação 1 para os controles PID, MPC e DMPC.....	72
Figura 63: Comparação entre as ações de controle MPC e DMPC.....	73

SUMÁRIO

1. INTRODUÇÃO	11
1.1. Objetivos	13
1.2. Principais Contribuições do Trabalho	14
1.3. Organização da Tese	14
2. REVISÃO BIBLIOGRÁFICA.....	16
2.1. Controle preditivo baseado em modelo (MPC).....	16
2.2. Controle preditivo distribuído baseado em modelo (DMPC).....	18
2.3. Identificação de sistemas por redes neurais	19
2.3.1. Rede Feedforward.....	21
2.3.2. Rede Feedback	21
2.3.3. Treinamento	22
3. PROCESSO FERMENTATIVO INTEGRADO 1G/2G	23
3.1. Determinação de parâmetros cinéticos.....	24
3.2. Modelo matemático para o processo contínuo de fermentação	26
3.2.1. Balanço de energia:.....	26
3.2.2. Taxa de Reciclo	28
3.3. Análise dinâmica do processo	29
3.4. Conclusões.....	30
3.5. Nomenclatura do modelo	31
4. PROCESSO DE DESTILAÇÃO ETANOL-ÁGUA	32
4.1. Modelo matemático do processo de destilação	32
4.1.1. Balanço de massa e componente:	33
4.1.2. Balanço de energia:.....	33
4.1.3. Relações de equilíbrio líquido vapor	35
4.2. Análise dinâmica do processo de destilação.....	36
4.3. Conclusões.....	39
4.4. Nomenclatura do modelo	39
5. CONTROLE MPC NO PROCESSO FERMENTATIVO	40
5.1. Introdução	40

5.2.	Escolha das variáveis	41
5.3.	Limitações do processo	41
5.4.	Modelo neural da fermentação	41
5.5.	Implementação do controlador no processo de fermentação	45
5.6.	Conclusões	53
6.	CONTROLE MPC NO PROCESSO DE DESTILAÇÃO	54
6.1.	Introdução	54
6.2.	Escolha das variáveis	54
6.3.	Limitações do processo	55
6.4.	Modelo neural da destilação	56
6.5.	Implementação do controlador no processo de destilação	60
6.6.	Conclusões	65
7.	CONTROLE DISTRIBUÍDO PARA A PLANTA	66
7.1.	Análise dinâmica da planta de produção de etanol	66
7.2.	Aplicação da estratégia de controle distribuído	69
8.	CONCLUSÕES E SUGETÕES DE TABALHOS FUTUROS	74
8.1.	Conclusão	74
8.2.	Sugestões de trabalhos futuros	74
9.	REFERÊNCIAS	76
	APÊNDICE A	79
	ANEXO 1	80

CAPÍTULO 1

1. INTRODUÇÃO

A produção de bioetanol se iniciou no Brasil na década de 1920 quando o Instituto de Açúcar e Álcool foi criado para auxiliar o governo a regular a produção de cana de açúcar. Depois da primeira crise do petróleo em 1973, o governo brasileiro criou o programa *Pro-Álcool* para desenvolver novas fontes de energia a partir da cana de açúcar. Aquele programa auxiliou na implantação e aprimoramento de plantas produtoras de álcool, tendo como principal objetivo, a produção de etanol anidro com a finalidade de misturá-lo à gasolina, bem como a sua utilização integral em novos motores para carros populares (SOUZA et al., 2014).

O etanol de primeira geração, feito a partir de plantas com alto teor de açúcar, como a beterraba, o milho (amido) e a cana de açúcar (caldo da cana), têm sua produção difundida mundialmente. Entretanto, a produção de etanol a partir de fontes diretas de açúcar pode não ser suficiente para atender à demanda crescente por estes combustíveis. Além disso, o uso de alimentos na produção de etanol pode acarretar no aumento de seus valores. Como alternativa à estes problemas, o etanol pode também ser produzido a partir de materiais lignocelulósicos, como o bagaço da cana de açúcar, ou resíduos agrícolas (BRETHAUER; WYMAN, 2010), que é comumente chamado de etanol de segunda geração ou etanol 2G.

As pesquisas para as novas tecnologias envolvendo o etanol de segunda geração podem ser divididas em quatro rotas principais: A hidrólise química, onde o bagaço de cana passa por um pré-tratamento e depois é adicionado ácido para produzir açúcares fermentáveis; Hidrólise enzimática, a fonte de celulose é submetida a um processo enzimático para quebrar o polímero em açúcares após um pré-tratamento, dentre os quais os mais comuns sendo hidro-térmico (catalisado com ácido ou não) ou o processo de explosão a vapor (catalisado por ácido ou não); auto hidrólise, que utiliza de biomassa geneticamente modificada com enzimas; e a hidrólise de pentose acoplada. A implantação do etanol celulósico tem um potencial de incremento de produção em torno de 40%, o que pode, eventualmente, aumentar a competitividade deste combustível frente à gasolina (BUCKERIDGE; DANTAS, 2014). Desta forma, a utilização açúcares provenientes do processo 2G e 1G podem aumentar a produção de etanol.

A conversão destes açúcares e separação para o produto final é feita por duas operações principais: A fermentação e a destilação. Na operação de fermentação ocorre uma reação de transformação dos açúcares em etanol. Posteriormente, no processo de destilação, ocorre o aumento da concentração de etanol através da separação pela volatilidade relativa dos componentes da mistura.

A fermentação apresenta uma dinâmica lenta e com não linearidades, o que dificulta consideravelmente o desenvolvimento de um controle eficiente (DAHOU et al., 1992). Além desse aspecto, pode-se esperar variações ainda maiores no processo de fermentação de 2ª geração devido as variabilidades nas concentrações de açúcares oriundos do material lignocelulósico e presença de inibidores, como mostrado por HERRERA (2016) e YAMAKAWA et al. (2019).

A destilação, por sua vez, é um importante processo de separação que usa grandes quantidades de energia, representando um percentual considerável no consumo das utilidades da cadeia de produção de etanol (MULIA-SOTO; FLORES-TLACUAHUAC, 2011). Apesar dos avanços da tecnologia de destilação obtidos principalmente pelas refinarias de petróleo, ainda existe certa dificuldade no controle deste processo nas indústrias (MISHRA; KUMAR; RANA, 2015). Além da dificuldade individual de cada uma dessas operações, existe também o problema de interação entre os processos, onde os distúrbios dos processos anteriores afetam diretamente as operações subsequentes.

Os sistemas de controle convencionais como o Proporcional-Integral-Derivativo (PID) calculam ação de controle através da variável de saída do processo. Este tipo de controlador tem sido utilizado de forma eficiente nos últimos anos para os mais diversos tipos de processos químicos (ANG et al., 2005). Por outro lado, o controle preditivo baseado em modelo (MPC) utiliza um modelo do processo para antecipar a ação de controle através de uma rotina de otimização (CARLOS; PRETI; MORARI, 1989). Esta estratégia possibilitou o aumento na performance do controle em múltiplos processos através do controle centralizado, o qual considera toda a planta industrial como um problema multivariável (MIMO). Entretanto, esse tipo de estratégia pode não ser eficiente em sistemas com alta complexidade (HOCALAR, 2010); como, por exemplo, uma planta de produção de etanol. Nesse caso, o aumento do número de variáveis de decisão, variáveis de estado e medições eleva o esforço computacional necessário para a implementação de um controle centralizado

Este aumento na complexidade do problema de otimização limita o desempenho destes tipos de controladores, especialmente quando se trata de problemas de otimização não lineares sujeitos a restrições (CHRISTOFIDES et al., 2013). Isto motivou o desenvolvimento de controladores distribuídos, que utilizam um conjunto de controladores que calculam separadamente a ação de cada processo, porém, com algum nível de comunicação entre eles. Esta comunicação entre os controladores de cada processo visa alcançar o objetivo global do processo, caracterizando um controle distribuído (CAMPONOGARA et al., 2002; ROCHA, 2014).

Neste sentido, este trabalho propõe a implementação de um controle preditivo baseado em modelo com estratégia distribuída (DMPC), de forma a antecipar os efeitos das ações de controle em cada operação sujeita à influência de outra anterior. Os controladores possuem como modelo interno as redes neurais artificiais (assim como o MPC), que são modelos capazes de tratar com não linearidades e também ruídos que normalmente estão presentes nas medidas experimentais. Deve-se ressaltar ainda o caráter universal que o procedimento proposto apresenta, pois as redes neurais podem ser treinadas a partir de um conjunto de dados de entrada e saída, não sendo necessário o desenvolvimento de modelos determinísticos ou mesmo modelos do tipo respostas aos estímulos que são mais custosos para o desenvolvimento e estabelecimento do modelo.

1.1. Objetivos

Este trabalho tem como objetivo geral o desenvolvimento de uma estratégia de controle distribuída para uma unidade de produção de etanol anidro, utilizando a configuração de controle distribuído preditivo.

Como objetivos específicos temos:

- Modelagem fenomenológica dos processos de fermentação e de destilação, os quais servirão para representar o processo e verificar o desempenho do controlador proposto;
- Simulação e análise dinâmica dos processos de fermentação e destilação;
- Desenvolvimento de um modelo neural para as operações de destilação e fermentação e posterior aplicação na implementação do controle preditivo centralizado para cada operação;

- Desenvolvimento da estratégia de controle, do controlador preditivo com modelos internos baseados em redes neurais artificiais e aplicação do controle distribuído na unidade de produção etanol;

1.2. Principais Contribuições do Trabalho

As principais contribuições deste trabalho podem ser elencadas como:

- Desenvolvimento de um *software* em MATLAB para a simulação do processo de produção de etanol, integrando o processo de fermentação com duas colunas de destilação;
- Aplicação de controladores PID no processo de fermentação e destilação;
- Desenvolvimento do controlador preditivo (MPC) e preditivo distribuído (DMPC) para a planta, ambos utilizando o modelo neural;
- Disponibilização do código de programação para estudos futuros no Laboratório de Otimização de Processos e Controle Avançado (LOPCA).

1.3. Organização da Tese

O Capítulo 2 apresenta uma revisão bibliográfica e conceitos básicos para o embasamento teórico da tese. A revisão aborda o controle Preditivo Baseado em Modelo (MPC), controle distribuído preditivo (DMPC) e os conceitos essenciais sobre a identificação de sistemas por redes neurais artificiais.

O Capítulo 3 descreve o processo fermentativo usado para a aplicação do controle, mostrando como as equações fenomenológicas regem o processo. Também é mostrado como foram obtidos os parâmetros cinéticos do modelo de forma a simular um processo integrado de primeira e segunda geração. Também foi feita uma análise dinâmica da operação.

No Capítulo 4 é mostrado o processo de destilação, bem como o modelo matemático que descreve o processo. Além disso é apresentada uma análise dinâmica do processo, essencial para a posterior implementação do sistema de controle.

Nos Capítulos 5 e 6 são apresentadas a metodologia de implementação do controlador MPC no processo de fermentativo e de destilação, respectivamente. Além disso, é apresentada a

metodologia usada para a obtenção do modelo neural artificial a partir da geração de dados e treinamento da rede neural artificial.

O Capítulo 7 mostra como foi feita a implementação do Controle Preditivo Distribuído Baseado em Modelo Neural (DMPC), comparando-o com o controle MPC convencional e o controle PID.

O Capítulo 8 apresenta a conclusão dos resultados obtidos no estudo e sugestões de trabalhos futuros.

CAPÍTULO 2

2. REVISÃO BIBLIOGRÁFICA

Neste capítulo será apresentada uma revisão sobre o controle preditivo baseado em modelo MPC, bem como sua formulação matemática e os principais tipos de arquitetura encontrados na literatura. Também será apresentada uma revisão sobre a identificação de sistemas através de redes neurais artificiais (RNA), as principais arquiteturas desta metodologia e os critérios de desempenho. Será apresentada também uma revisão sobre o MPC distribuído, bem como os principais estudos relacionados à esta tecnologia.

2.1. Controle preditivo baseado em modelo (MPC)

O controle preditivo baseado em modelo vem sendo amplamente estudado para a aplicações onde se necessita de um controle eficiente em meio à processos multivariáveis e com restrições operacionais. O MPC opera na otimização da variável manipulada de forma que a trajetória futura do sistema seja mais próxima possível do *set-point* (CHRISTOFIDES et al., 2013). Em outras palavras, o MPC calcula uma sequência de ajustes nas variáveis manipuladas com o objetivo de otimizar o comportamento futuro do processo. Originalmente, o MPC foi desenvolvido especificamente para as refinarias de petróleo; hoje este tipo de tecnologia pode ser encontrada nos mais diversos setores da indústria tais como: alimentos, combustíveis, polímeros, entre outras (JORGENSEN; PETERSEN; RAWLINGS, 2015; LAO; ELLIS; CHRISTOFIDES, 2014; QIN; BADGWELL, 2003).

Para apresentar a formulação de um controlador MPC em um processo, considere um sistema representado por uma equação de espaço-estado (equações 1 e 2). A saída pode ser medida a cada instante de tempo discreto k e essa medição é enviada ao controlador

$$x_{k+1} = A_k + Bu_k \quad (1)$$

$$y_k = Cx_k \quad (2)$$

onde x_k é o estado do sistema, u_k é a entrada do controlador, y_k é a saída do sistema; A , B e C são matrizes de estado, entrada e saída, respectivamente. O controlador toma a decisão baseada em

uma função custo (equação 3) que leva em consideração o esforço da ação de controle e a diferença entre a saída predita do sistema e o valor de referência.

$$J(u) = \alpha \sum_{i=1}^{N_y} (y'_{k+i} - set)^2 + \beta \sum_{i=1}^{N_u} (\Delta u)^2 \quad (3)$$

Sujeito à:

$$Min < u < Máx$$

onde y'_{k+i} é a predição dos valores futuros da saída do processo até o horizonte de predição N_y ; set é o valor de referência; β e α são as constantes de penalização para a ação de controle e sobre o erro no *set-point*, respectivamente; N_u é o horizonte de controle. Os valores de predição y'_{k+i} são obtidos através de um modelo neural obtido através dos modelos fenomenológicos da planta e Δu é fornecido pelo algoritmo de otimização a cada iteração. N_u e N_y são as variáveis do controlador a serem sintonizadas.

A saída predita y'_{k+i} é obtida por um modelo representativo do processo, que, através da execução de uma simulação recursiva, obtém os valores da saída no processo em um futuro definido por N_y . A simulação recursiva é feita apenas com os valores atuais das variáveis que influenciam o processo.

Num dado instante de tempo k , o sensor de saída do processo envia a informação da saída y_k para o controlador, que, através de um método de otimização não linear, encontra o mínimo da função custo $J(u)$ (equação 3). O primeiro valor obtido da ação de controle u_k é enviada ao processo. A otimização está sujeita, em muitos casos, a restrições relacionadas ao processo, compondo assim um problema de otimização não linear com restrições. A Figura 1 mostra um esquema descritivo das variáveis do controle MPC:

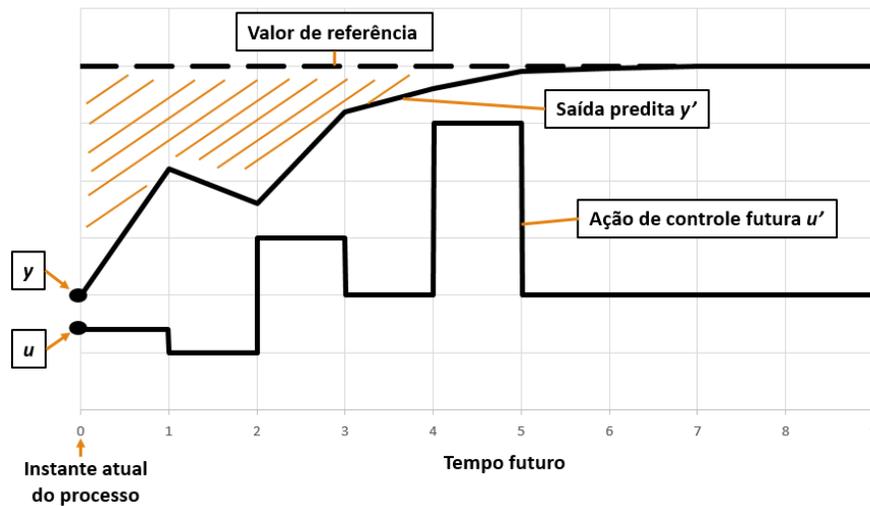


Figura 1: Esquema do funcionamento do controle preditivo.

Este processo se repete a cada instante de tempo k , calculando uma nova ação de controle a cada iteração. Esta atualização no valor de u é chamada de horizonte móvel.

2.2. Controle preditivo distribuído baseado em modelo (DMPC)

Continuamente, diversas estratégias de controle processos vêm sendo desenvolvidas e aperfeiçoadas, tal como o controle PID que é amplamente utilizado devido seu baixo custo de implementação e o Controle Preditivo Baseado em Modelo (MPC) que utiliza de um modelo do processo para prever as ações futuras de controle.

A aplicação de controle independente pode gerar um efeito cascata na resposta do processo, onde eventuais erros de operação são propagados para as etapas seguinte. Entretanto, a aplicação de um controle distribuído baseado em modelo (DMPC) pode evitar este tipo de problema (CHRISTOFIDES; SCATTOLINI; MU, 2013). O DMPC é uma tecnologia ainda em evolução, por isto, existem poucos artigos tratando esta metodologia de controle para processos industriais (CAMPONOVARA et al., 2002). ROCHA (2018) estudou o efeito do controlador DMPC cooperativo e não cooperativo em processos não lineares. DAOUTIDIS; TANG e JOGWAR (2017) fizeram um estudo de como melhorar a decomposição de plantas complexas para a implementação do controlador DMPC e VENKAT et. al (2005) apresentou um estudo sobre a estabilidade e condições “ótimas” para controles distribuídos baseados em modelo.

Essencialmente, o DMPC calcula as possíveis ações de controle de cada sistema tendo como função objetivo a diminuição do custo operacional, segurança ou produtividade, por exemplo, da planta como um todo. No MPC convencional a ação de controle independe das decisões dos MPC's de outras partes do processo, no DMPC existe uma comunicação de decisões entre processos que tem influência um sobre os outros. Por exemplo, considere um processo composto por dois sistemas, no qual a saída do sistema 1 equivale à entrada do sistema 2. Para o MPC convencional (Figura 2), as decisões dos MPC's 1 e 2 são feitas considerando apenas o sistema que está inserido. Já no DMPC (Figura 3), o MPC 1 envia as decisões futuras ao MPC 2, permitindo com que o segundo MPC use essas informações na otimização do sistema 2.

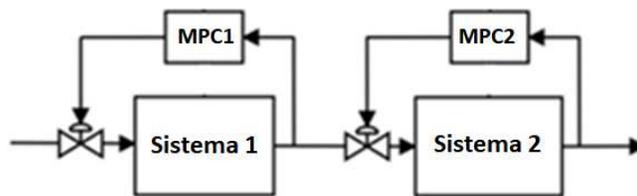


Figura 2: Configuração do controlador MPC convencional para dois sistemas.

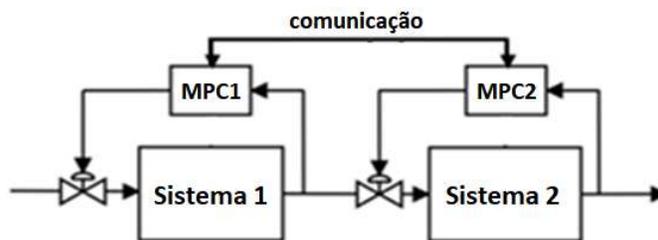


Figura 3: Configuração do controlador DMPC para dois sistemas.

Essas considerações motivam o desenvolvimento de sistemas de controle distribuído que utilizam uma matriz de controladores com blocos de cálculos separados e ainda se comunicam entre si para alcançar os objetivos da planta em malha fechada (CHRISTOFIDES; SCATTOLINI; MU, 2013; MOROSAN et al., 2010; VENKAT; RAWLINGS; WRIGHT, 2005).

2.3. Identificação de sistemas por redes neurais

O controle preditivo baseado em modelo é uma ferramenta fundamental em boa parte das refinarias ao redor do mundo e sua aplicação continua crescendo do meio industrial (GUPTA, 2013; MELEIRO; FILHO, 2000). O modelo de predição é de fundamental importância para a execução deste tipo de controle e seu desempenho dependerá diretamente da qualidade deste

modelo (QIN; BADGWELL, 2003). As redes neurais artificiais se apresentam como uma ferramenta eficiente para a identificação de processos químicos (SHEMYAKINA; TARKHOV, et al., 2016), podendo ser usado como modelo neural de predição nos controladores preditivos.

As redes neurais artificiais são modelos computacionais com o objetivo de reproduzir a forma que o cérebro humano processa informações e são treinadas para aprender a reproduzir informações através de exemplares pré-existentes (AGATONOVIC-KUSTRIN; BERESFORD, 2000) conforme esquematizado na Figura 4.

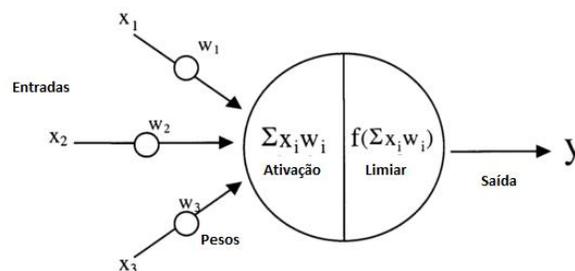


Figura 4: Estrutura de um neurônio artificial. Fonte: (AGATONOVIC-KUSTRIN; BERESFORD, 2000).

As redes neurais artificiais são compostas basicamente de elementos de cálculos chamados neurônios que interagem localmente através de conexões e, no geral, é dividida em três camadas: camada de entrada, camada intermediária e camada de saída. A arquitetura destes modelos é determinada pela topologia da rede, pelo algoritmo de aprendizagem e pelas características destes neurônios. Os elementos de cálculo são processadores que são compostos por uma função que possui n entradas e apenas uma saída. Cada neurônio necessita de uma regra que indica a influência em cada entrada x na sua saída y ; tais regras são chamadas de pesos (w) e podem ser definidos como a memória de aprendizado da rede.

Os neurônios necessitam de uma função de saída que mapeia o estado corrente de ativação para um sinal de saída. A função de saída utilizada é uma função limiar na qual só existirá sinal de saída apenas se for atingido um valor mínimo para esta função (HOSKINS; HIMMELBLAU, 1988). Então, mesmo com a função de ativação receber sinais de entrada, este sinal precisa ser maior que um mínimo estipulado na função limiar. Dentre os vários tipos de arquitetura de rede, destacam-se a rede *Feedforward* e a rede *Feedback*.

2.3.1. Rede Feedforward

Usualmente, o algoritmo de treino para este tipo de rede envolve o erro da saída. O treinamento ocorre apenas em um único sentido (Figura 5). Isto é, a saída de cada camada se relaciona, exclusivamente, com a camada subsequente e nunca com a cama anterior (RAZBANI; ASSADI, 2014).

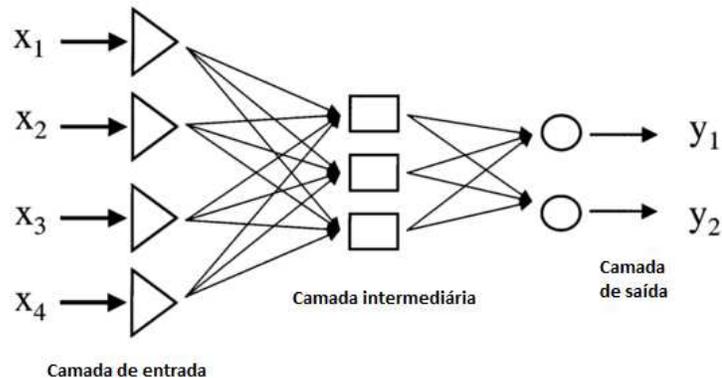


Figura 5: Rede Feedforward. Fonte:(AGATONOVIC-KUSTRIN; BERESFORD, 2000).

2.3.2. Rede Feedback

Diferente da rede *Feedforward*, a arquitetura *Feedback* permite a comunicação entre a saída e entrada na mesma camada, cada neurônio tem um peso adicional como entrada que irá permitir um grau de liberdade adicional quando o erro de treinamento for minimizado (AGATONOVIC-KUSTRIN; BERESFORD, 2000). A vantagem desta arquitetura é que, quando a rede for treinada ela não dependerá apenas dos dados de entrada, mas também do estado anterior da rede.

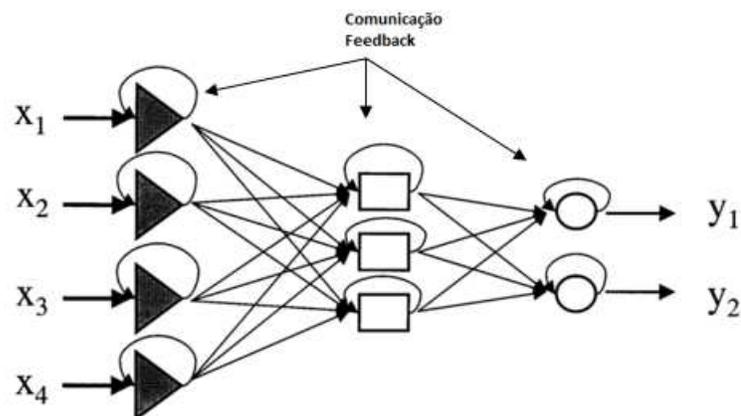


Figura 6: Rede Feedback. Fonte: (AGATONOVIC-KUSTRIN; BERESFORD, 2000).

2.3.3. Treinamento

As Redes Neurais Artificiais são treinadas usando aprendizagem supervisionada, com um conjunto de treinamento de entradas pn e alvos tn . A função objetivo é minimizar a soma dos erros quadráticos (SSE):

$$SSE = \sum_{i=1}^n (tn_i - rn_i)^2 \quad (4)$$

onde rn_i é a resposta da rede neural. O algoritmo de Levenberg-Marquardt atualiza o peso de forma a minimizar o SSE para os dados de treinamento. Além do SSE, o erro quadrado médio (MSE) também pode ser usado como um critério de desempenho, o que evita a soma cumulativa de erros para um grande conjunto de dados através divisão para o número de amostras m :

$$MSE = \frac{1}{m} \sum_{i=1}^n (tn_i - rn_i)^2 \quad (5)$$

A Regularização Bayesiana pode ser adicionada à função objetivo:

$$F = \alpha.MSE + \beta.W \quad (6)$$

onde o parâmetro W representa a soma dos quadrados dos pesos da rede. Com um valor elevado de β , a rede tende a minimizar o valor dos pesos, resultando numa resposta mais suave. Se α é alto, então a resposta de rede tende a minimizar o erro e sem penalização de tamanho do peso β o treinamento pode gerar uma rede com uma resposta com sobre-ajuste indesejável.

Portanto, as redes neurais artificiais vêm desempenhando um importante papel na caracterização, simulação e controle de processos. Seu principal atrativo é a possibilidade de reproduzir sistemas de alta complexidade apenas com a utilização de dados experimentais e sem a necessidade do conhecimento fenomenológico do sistema. Além disso, as redes neurais artificiais também têm sua aplicabilidade bem-sucedida em áreas como: o setor de combustíveis (RAZBANI; ASSADI, 2014); Aplicações em estatística (SARLE, 1994); detecção de falhas (PAYA; ESAT; BADI, 1997) entre muitas outras aplicações como controle de tráfego aéreo, previsão do tempo e reconhecimento de voz.

CAPÍTULO 3

3. PROCESSO FERMENTATIVO INTEGRADO 1G/2G

No processo integrado de produção de etanol (1ª e 2ª geração), o bagaço e a palha da cana de açúcar são utilizados na cogeração de combustíveis para o sistema. O excedente de bagaço da produção de vapor é destinado para o pré-tratamento e hidrólise para a produção de açúcares fermentescíveis (pentoses e hexoses) e posteriormente misturados ao caldo rico em sacarose, proveniente da etapa de extração de açúcares (DIAS et al., 2013). Após o processo de fermentação, o vinho deslevedurado passa por algumas etapas de destilação e desidratação até a formação do etanol anidro (Figura 7).

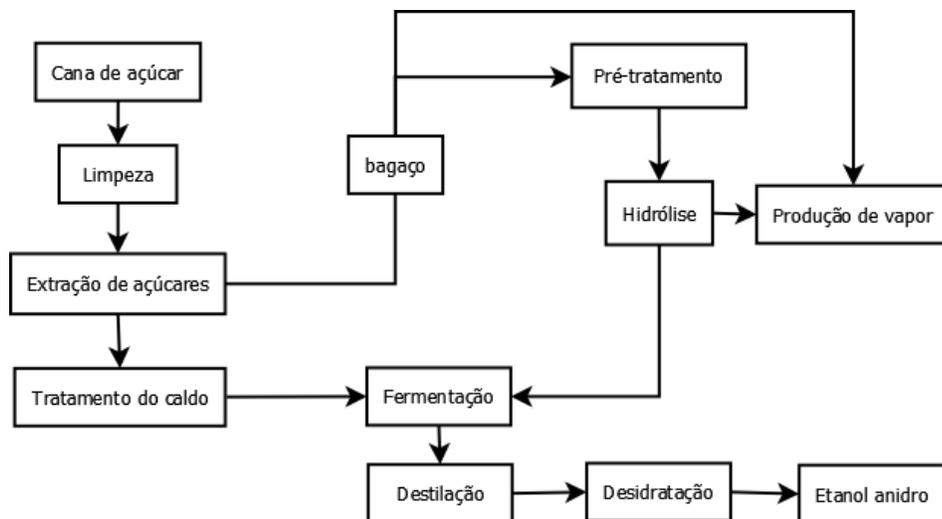


Figura 7: Fluxograma de uma unidade de produção integrada de etanol de primeira e segunda geração a partir da cana de açúcar. Fonte: adaptação de DIAS et al. (2013).

O processo estudado é a fermentação contínua com quatro biorreatores de mistura perfeita em série. A simulação dinâmica do processo foi implementada em ambiente MATLAB. Neste estudo, foi considerada uma mistura de açúcar proveniente da hidrólise da celulose do bagaço da cana de açúcar com o caldo de cana de açúcar. A conversão em etanol será conduzida pela levedura *Sacharomyces cerevisiae*. Um conjunto de centrífugas divide o mosto fermentado em duas fases: fase leve, enviada para a destilação; e a fase pesada, que é submetida a tratamento ácido, diluída em água e reciclada para o primeiro fermentador (MELEIRO; VON ZUBEN;

FILHO, 2009). O sistema escolhido foi baseado em um esquema de fermentadores em escala industrial proposto por ANDRIETA (1994) (Figura 8).

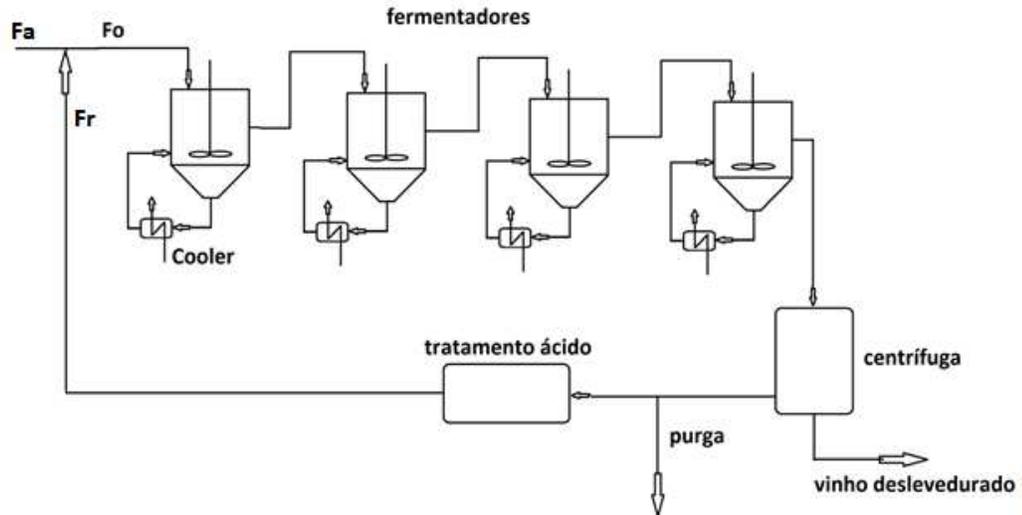


Figura 8: Processo de fermentação contínua com reciclo de células.

3.1. Determinação de parâmetros cinéticos

O modelo cinético no processo fermentativo considera três relações principais: a taxa de crescimento celular r_x , a taxa de consumo de substrato r_s e a taxa de produção de etanol r_p . A taxa de crescimento celular é composta essencialmente por termos de inibição pela concentração de substrato, inibição pela concentração de produto e inibição pela concentração de células (equação 7). Existem diversas equações que representam cada um desses termos (ANDRIETA, 1994).

A equação utilizada na fermentação para a inibição do crescimento celular é dada pela alta concentração de substrato sugerida por KELLER e DUNN (1978). A inibição pela concentração de produto é sugerida por LUONG (1985) e o termo de inibição celular é baseado na equação sugerida por CHATTAWAY *et al* (1988).

$$r_x = \frac{dX}{dt} = u_{max} \frac{S}{K_s + S + \frac{S^2}{K_I}} \left(1 - \frac{P}{P_{max}}\right)^r \left(1 - \frac{X}{X_{max}}\right) X \quad (7)$$

$$r_s = \frac{dS}{dt} = \frac{r_x}{y_{X/S}} \quad (8)$$

$$r_p = \frac{dP}{dt} = \frac{r_x}{y_{X/P}} \quad (9)$$

onde S é a concentração de substrato, u_{max} é a velocidade específica de crescimento máxima do microrganismo (h^{-1}), r é o termo exponencial de inibição pelo produto, P_{max} e X_{max} são a concentração de etanol e a concentração de células onde o crescimento celular cessa, respectivamente. K_S a constante de afinidade e K_I é a constante de inibição pelo substrato em g/L. $y_{X/S}$ e $y_{X/P}$ são os rendimentos teóricos de substrato e etanol, respectivamente.

Os parâmetros cinéticos foram obtidos em experimentos realizados por HERRERA et al. (2016), onde se utilizou a integração entre os processos 1G e 2G para a obtenção dos açúcares e, posteriormente, uma fermentação desses açúcares em um processo de fermentação em batelada. Como os parâmetros cinéticos variam de acordo com a temperatura (T) (ANDRIETA, 1994), utilizou-se equações dependentes da temperatura para o ajuste dos parâmetros (eq. 10 e 11). A Tabela 1 mostra o resultado do ajuste para cada parâmetro cinético do modelo feito por HERRERA et al. (2016).

Equação de regressão para os parâmetros cinéticos $K_S, u_{max}, K_I, P_{max}, X_{max}$ e r :

$$\varphi(T) = e^a \cdot e^{bT} \cdot e^{\frac{c}{T}} \quad (10)$$

Equação de regressão para os parâmetros cinéticos $y_{X/S}$ e $y_{X/P}$

$$\gamma(T) = e^d \cdot e^{ET^3} \cdot e^{f \cdot e^T} \quad (11)$$

Equação	Parâmetro	exp(a)	b	c	exp(d)	E	f
φ	u_{max}	26,732	-0,4139	-454,437	-	-	-
φ	K_S	42,500	-0,5291	-735,026	-	-	-
φ	K_I	34,436	-0,4743	-468,766	-	-	-
φ	r	3,2319	-0,0751	-29,331	-	-	-
φ	P_{max}	25,089	-0,3136	-337,121	-	-	-
φ	X_{max}	18,501	-0,1913	-257,809	-	-	-
γ	$\frac{y_X}{S}$	-	-	-	-2,71221	-1,5.10 ⁻⁵	-8,09.10 ⁻¹⁸
γ	$\frac{y_X}{P}$	-	-	-	-2,22914	-5,24.10 ⁻⁶	-6,54.10 ⁻¹⁷

Tabela 1: Parâmetros do modelo do processo fermentativo de segunda geração (HERRERA et al., 2016).

3.2. Modelo matemático para o processo contínuo de fermentação

Os volumes dos fermentadores utilizados neste trabalho são: $V_1 = 210,374 \text{ m}^3$, $V_2 = 268,037 \text{ m}^3$, $V_3 = 316,663 \text{ m}^3$, $V_4 = 208,208 \text{ m}^3$, operando com uma taxa inicial de reciclo de células de 0,3, uma concentração de substrato de 180 Kg/m^3 com uma vazão de alimentação de $100 \text{ m}^3/\text{h}$. Estes valores de parâmetros foram baseados no trabalho de ANDRIETA (1994) onde se estudou o processo de fermentação contínua em escala industrial. A temperatura de operação de cada reator foi de $32,5^\circ\text{C}$. As equações 12 a 15 mostram o balanço de massa para o reator i :

- Balanço de massa global:

$$\frac{dV_i}{dt} = F_{i-1} - F_i \quad (12)$$

Vale ressaltar que para $i = 1$, $F_0 = F_a + F_r$, onde F_a é a vazão de alimentação do sistema e F_r é a vazão de refluxo, como mostra a Figura 8.

- Balanço de substrato (S):

$$\frac{d(V_i S_i)}{dt} = F_{i-1} S_{i-1} - F_i S_i + r_s V_i \quad (13)$$

- Balanço de etanol (P):

$$\frac{d(V_i P_i)}{dt} = F_{i-1} P_{i-1} - F_i P_i + r_p V_i \quad (14)$$

- Balanço de células (X):

$$\frac{d(V_i X_i)}{dt} = F_{i-1} X_{i-1} - F_i X_i + r_x V_i \quad (15)$$

3.2.1. Balanço de energia:

O processo fermentativo tem característica exotérmica devido a reações do metabolismo celular; esse calor gerado é considerado no modelo através do balanço de energia. Para a modelagem desta condição, considerou-se constantes as densidades dos fluidos, bem como suas capacidades caloríficas. Um maior detalhamento das deduções das equações apresentadas pode ser visto no trabalho de ANDRIETA (1994). A Figura 9 mostra de forma esquemática as correntes relacionadas ao resfriamento do reator CSTR.

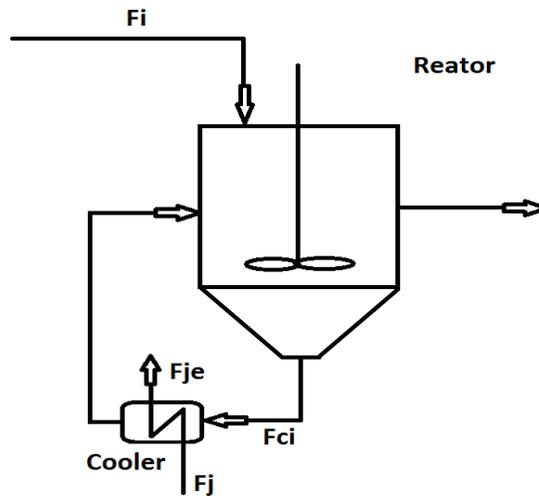


Figura 9: Esquema das correntes do reator.

A Tabela 2 mostra os valores das constantes referentes ao cálculo do balanço energético do processo.

Calor da reação	-157,57 Kcal/h
Massa específica do fluido refrigerante	950 Kg/m ³
Capacidade térmica específica do fluido refrigerante	1 cal/g.°C
Coefficiente global de troca térmica	3500 Kcal/h.°C.m ²
Massa específica do fluido reagente	1000 Kg/m ³
Temperatura do fluido refrigerante	28°C

Tabela 2: Constantes do balanço energético.

Vale ressaltar que a capacidade térmica do fluido refrigerante e do fluido reagente permanece constante com as variações de temperatura. O modelo matemático do processo fermentativo considerou o balanço de energia para cada um dos quatro reatores CSTR em série, descritos pelas equações de 16 a 18.

- Balanço de energia para o fluido reagente nos reatores:

Para a massa específica do fluido reagente (ρ) e sua capacidade calorífica (C_p) constantes tem-se que:

$$\frac{d(V_i T_i)}{dt} = F_{i-1} T_{i-1} - F_i T_i + F c_i (T c_i - T_i) + \frac{V_i \Delta H}{\rho C_p} r_s \quad (16)$$

- Balanço de energia para o fluido reagente nos trocadores de calor:

Considerando o volume do fluido reagente nos trocadores de calor constante, tem-se que:

$$\frac{d(Tc_i)}{dt} = \frac{Fc_i}{Vc_i}(T_i - Tc_i) - \left(\frac{UA_i}{Vc_i\rho C_p}\right)LMDT_i \quad (17)$$

- Balanço de energia para o fluido de resfriamento nos trocadores de calor:

Considerando o volume de fluido de resfriamento constante:

$$\frac{d(Tj_i)}{dt} = \frac{Fj_i}{Vj_i}(Tj_e - Tj_i) - \left(\frac{UA_i}{Vj_i\rho_j C_{pj}}\right)LMDT_i \quad (18)$$

onde i representa cada um dos quatro estágios da fermentação, j e j_e representam o fluido de resfriamento que chega e sai do trocador de calor respectivamente; c é a constante reativa no cooler; V é o volume do reator, T é a temperatura, P é o fluxo volumétrico; S , X e P são as concentrações do substrato, de células e de etanol respectivamente; ρ , C_p e ΔH são parâmetros físicos do meio: Massa específica, capacidade calorífica e entalpia da reação respectivamente. O método de Runge-Kutta de quarta ordem foi utilizado como método de integração, com um passo de 0.01.

3.2.2. Taxa de Reciclo

Como mostra a Figura 8, a corrente de reciclo após o tratamento ácido (F_r) se soma com a corrente de alimentação (F_a) para formar a corrente de entrada do primeiro fermentador (F_0). A taxa de reciclo é dada pela razão entre F_0 e F_r (equação 19), o valor inicial para esta variável foi de 0.3. ANDRIETA (1994) definiu este valor baseado nos processos de batelada alimentada, nos quais o volume de fermento tratado é igual à aproximadamente 30% do volume total do reator. Como dinâmica do processo fermentativo é mais lenta que a unidade de tratamento das leveduras no reciclo, o comportamento dinâmico desta parte do processo é desprezado (MELEIRO, 2002).

$$T_r = \frac{F_r}{F_0} \quad (19)$$

3.3. Análise dinâmica do processo

Para entender melhor como as variáveis influenciam o processo de fermentação, uma análise dinâmica do processo foi feita simulando o modelo do processo implementado no software MATLAB e seu código de implementação está apresentado no Anexo 1. Como variável controlada, foi escolhida a concentração de etanol no vinho deslevedurado, pois esta variável influenciará diretamente o processo de destilação posterior. Desta forma, a análise dinâmica da fermentação será feita de forma a identificar a variável manipulada que tenha o maior ganho em relação à concentração de etanol de saída. Fazendo perturbações degrau de +10% na vazão de alimentação (F_a) e da taxa de reciclo (T_r) têm-se a resposta dinâmica mostrada na Figura 10.

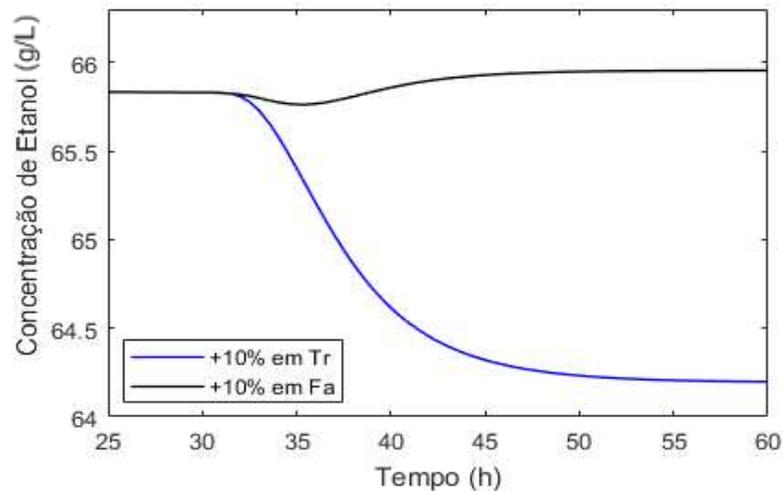


Figura 10: Perturbação da taxa de reciclo e na vazão de alimentação.

A simulação em um intervalo de tempo de 60 horas, com o tempo de amostragem na medição das variáveis de 30 minutos. A perturbação foi aplicada após atingir o estado estacionário, em 30 horas de simulação. A taxa de reciclo apresentou uma maior influência sobre a variável controlada com um ganho de 53,33, enquanto o ganho da vazão de alimentação sobre a variável manipulada foi de 0,012. Além disso, alterações na vazão de alimentação depende diretamente das etapas anteriores ao processo fermentativo, sendo assim, a taxa de reciclo fica definida como variável manipulada do sistema de controle.

A variável distúrbio do processo escolhida foi a de açúcares redutores totais (ART) de entrada (S_0) pois esta variável pode oscilar ao longo da operação da planta devido às etapas

anteriores da planta. A Figura 11 apresenta resposta do sistema para uma perturbação degrau de +10% e -10% na variável distúrbio S_0 .

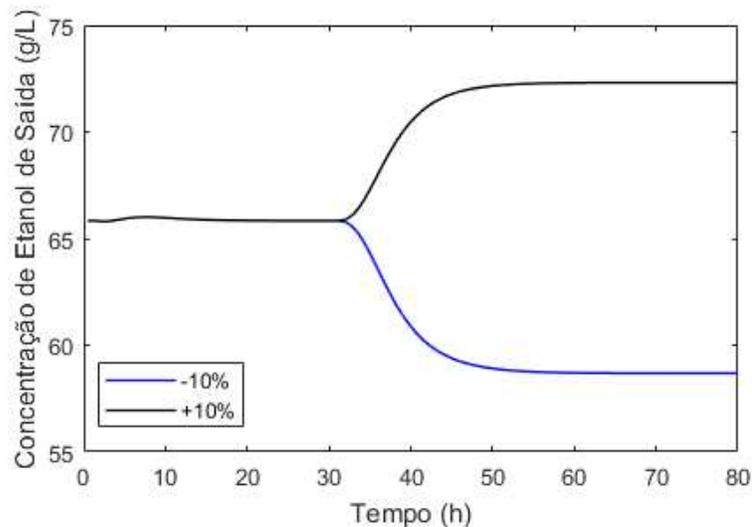


Figura 11: Perturbação na variável distúrbio do processo fermentativo S_0 .

A Figura 11 mostra que a variável distúrbio escolhida também possui influência considerável sobre o processo, tendo um ganho em torno de 0,344.

3.4. Conclusões

Neste capítulo foi estudado o modelo matemático do processo fermentativo, bem como sua análise dinâmica e definição das variáveis manipuladas, controladas e distúrbios do processo. A simulação dinâmica do modelo fenomenológico da fermentação mostrou que a taxa de reciclo possui maior influência sobre a concentração de etanol de saída se comparado com a vazão de alimentação, sendo assim escolhida como variável manipulada do processo. Além disso, a concentração de substrato na alimentação ficou definida como sendo a variável distúrbio. Esta variável será importante no estudo de problemas de controle do tipo regulador da fermentação, estudados no Capítulo 5.

3.5. Nomenclatura do modelo

C_p	Capacidade térmica específica do fluido reacional (cal/(g.°C))
F_0	Vazão de alimentação depois do reciclo (m ³ /h)
F_a	Vazão de alimentação antes do reciclo (m ³ /h)
F_r	Vazão de reciclo (m ³ /h)
K_I	Constante de inibição pelo substrato (g/L)
K_S	Constante de afinidade pelo substrato (g/L)
$LMDT_i$	Diferença média logarítmica do trocador de calor i
P_{max}	Concentração de etanol onde termina o crescimento celular (g/L)
S_0	Concentração de substrato na alimentação (g/L)
T_r	Taxa de reciclo
V_i	Volume do reator i
X_{max}	Concentração de células onde termina o crescimento celular (g/L)
r_p	Taxa de produção de etanol (g/(L.h))
r_s	Velocidade de consumo de substrato (g/(L.h))
r_x	Taxa de crescimento celular (g/(L.h))
u_{max}	Velocidade específica de crescimento máxima do microrganismo (h ⁻¹)
$\frac{y_x}{P}$	Rendimento teórico de etanol
$\frac{y_x}{S}$	Rendimento teórico de biomassa
ΔH	Entalpia de reação (Kcal/Kg)
P	Concentração de etanol (g/L)
S	Concentração de substrato (g/L)(ART)
T	Temperatura do meio reagente (K)
X	Concentração de células (g/L)
c	Constante de reação no trocador de calor
i	Índice identificador do reator (1 à 4)
j	Fluido de resfriamento de saída
je	Fluido de resfriamento de entrada
r	Termo exponencial de inibição pelo produto
ρ	Massa específica do fluido reacional (Kg/m ³)
C_p	Calor específico do meio reacional

CAPÍTULO 4

4. PROCESSO DE DESTILAÇÃO ETANOL-ÁGUA

4.1. Modelo matemático do processo de destilação

Na modelagem do processo de destilação, considerou-se duas colunas de destilação binária para a separação da mistura etanol/água (Figura 12). A alimentação da coluna 1 ocorre no estágio $n_f = 5$, a qual a composição da mistura corresponde à saída do processo fermentativo anterior. A seção de retificação possui um refluxo, o qual é fornecido por um condensador total e a seção de esgotamento possui um refeedor parcial. A vazão de destilado da coluna 1 ($D1$) corresponde à entrada da destilação 2 ($F2$) e a fração de etanol na corrente de destilado da primeira coluna ($fx1$) corresponde à fração de entrada na destilação 2 ($z2$). Ambas as colunas foram baseadas no modelo validado por SODRE et al. (2000) para destilação binária.

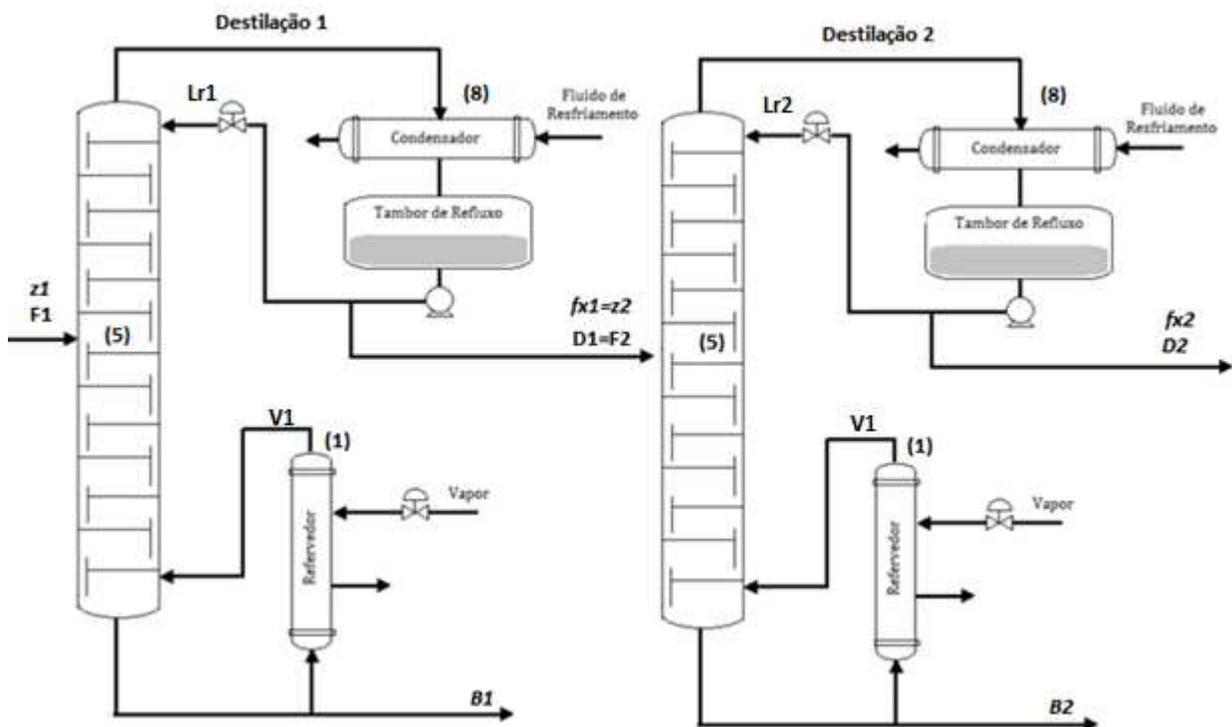


Figura 12: Processo de destilação binária.

Ambas as colunas possuem 7 estágios de equilíbrio e 1 estágio representando o condensador total. Para a modelagem do processo de destilação, foram considerados os balanços de massa e de energia descritos pelas equações 20 a 31:

4.1.1. Balanço de massa e componente:

- No estágio n :

$$\frac{dM_n}{dt} = L_{n+1} + V_{n-1} - L_n - V_n \quad (20)$$

$$\frac{dM_n x_n}{dt} = L_{n+1} x_{n+1} + V_{n-1} y_{n-1} - L_n x_n - V_n y_n \quad (21)$$

- No estágio de alimentação nf :

$$\frac{dM_{nf}}{dt} = F + L_{nf+1} + V_{nf-1} - L_{nf} - V_{nf} \quad (22)$$

$$\frac{dM_{nf} x_{nf}}{dt} = F z_f + L_{nf+1} x_{nf+1} + V_{nf-1} y_{nf-1} - L_{nf} x_{nf} - V_{nf} y_{nf} \quad (23)$$

- No refeedor, primeiro estágio ($n = 1$):

$$\frac{dM_1}{dt} = L_2 - V_1 - B \quad (24)$$

$$\frac{dM_1 x_1}{dt} = L_2 x_2 - V_1 y_1 - B x_B \quad (25)$$

- No condensador, último estágio ($n = N$):

$$\frac{dM_N}{dt} = V_{N-1} - L_r - D \quad (26)$$

$$\frac{dM_N x_N}{dt} = V_{N-1} y_{N-1} - L_r x_r - D x_D \quad (27)$$

4.1.2. Balanço de energia:

A vazão de alimentação e a vazão de refluxo são sub-resfriadas, portanto modelo considera a condensação do vapor que ascende à coluna através dos balanços de energia em cada estágio n .

- No estágio n :

$$\frac{dM_n h_n}{dt} = L_{n+1} h_{n+1} + V_{n-1} H_{n-1} - L_n h_n - V_n H_n \quad (28)$$

- No estágio de alimentação $n = n_f$:

$$\frac{dM_{n_f} h_{n_f}}{dt} = F z_f + L_{n_f+1} h_{n_f+1} + V_{n_f-1} H_{n_f-1} - L_{n_f} h_{n_f} - V_{n_f} H_{n_f} \quad (29)$$

- No refeededor, primeiro estágio ($n = 1$):

$$\frac{dM_1 h_1}{dt} = L_2 h_2 + V_1 H_1 - B h_B + Q_R \quad (30)$$

onde B é a vazão molar do produto de base e h_B sua entalpia; Q_R representa a taxa de calor fornecida pelo refeededor.

- No condensador, último estágio ($n = N$):

$$\frac{dM_N h_1}{dt} = V_{N-1} H_{N-1} + L_D h_D - D h_D - Q_c \quad (31)$$

onde D é a vazão molar do produto de topo e h_D sua entalpia; Q_c representa a taxa de calor removida pelo condensador; M_n representa o retido de líquido no estágio n ; V_n representa a vazão de vapor no estágio n ; x_n é a fração molar da fase líquida e y_n da fase vapor no estágio n ; h e H representam a entalpia em base molar da fase líquida e da fase vapor respectivamente e z_f é a fração de etanol na alimentação. L_n é o fluxo de líquido que escoo do estágio n para o $n-1$. O cálculo de L_n pode ser feito através da equação 32:

$$L_n = \frac{1}{\sigma} (M_n - M_0) \quad (32)$$

onde M_0 é o retido inicial de cada estágio. O valor parâmetro $\sigma = 0.1$ foi obtido no trabalho de SODRE et al. (2000), que validou experimentalmente o modelo da coluna de destilação utilizado. A vazão de alimentação e a vazão de refluxo são sub-resfriadas, portanto o modelo considera a condensação do vapor que ascende à coluna através dos balanços de energia.

O vapor gerado pelo refeededor é uma função da composição da mistura e da alimentação de vapor na sua serpentina. A equação foi obtida através de uma regressão linear e comparada com o processo real (SODRE et al., 2000) como mostra a equação 33. Este ajuste é necessário, pois a variável manipulada na base da coluna é a alimentação de vapor (utilidade) no refeededor (V_r), sendo necessária a conversão para o vapor que ascende no interior da coluna (V_r).

$$V_r = 0,0066. V_v + 0,1426 \times 1000 \quad (33)$$

4.1.3. Relações de equilíbrio líquido vapor

Para o cálculo do equilíbrio líquido-vapor da coluna, utilizou-se a lei de Raoult e a lei de Dalton. A lei de Dalton diz que a soma das pressões parciais de cada componente da mistura equivale à pressão do sistema (equação 34). Na lei de Raoult, a pressão parcial de cada componente em uma solução ideal é dependente da pressão de vapor dos componentes e da fração molar dos mesmos (equações 35 e 36).

$$P_{total} = P_{etanol} + P_{\acute{a}gua} \quad (34)$$

$$P_{etanol} = P_{etanol}^o \cdot x_{etanol} \quad (35)$$

$$P_{\acute{a}gua} = P_{\acute{a}gua}^o \cdot x_{\acute{a}gua} \quad (36)$$

onde P^o representa a pressão da substância pura e x a fração líquida de cada componente. Para uma destilação binária:

$$x_{etanol} + x_{\acute{a}gua} = 1 \quad (37)$$

$$y_{etanol} + y_{\acute{a}gua} = 1 \quad (38)$$

onde y representa a fração de vapor de cada componente. A partir da Lei de Dalton e de Raoult é possível obter a fração molar de etanol nas fases líquida (x_{etanol}) e vapor (y_{etanol}) usando a pressão de vapor saturado de cada componente e a pressão total do sistema (eq. 39 e 40):

$$x_{etanol} = \frac{P_{total} - P_{\acute{a}gua}^o}{P_{etanol}^o - P_{\acute{a}gua}^o} \quad (39)$$

$$y_{etanol} = \frac{P_{etanol}^o \cdot x_{etanol}}{P_{total}} \quad (40)$$

Os valores de P_{etanol}^o e $P_{\acute{a}gua}^o$ são funções da temperatura (T) do sistema e podem ser obtidos pela equação de Antoine (equação 41).

$$P_{etanol}^o = A_A - \frac{B_A}{C_A + T(K)} \quad (41)$$

A Tabela 3 mostra os valores das constantes de Antoine usados no modelo:

Constante	Etanol	Água
A_A	18,9119	18,3036
B_A	3803,98	3816,44
C_A	-41,68	-46,13

Tabela 3: Constantes de Antoine para etanol e água (K).

Vale ressaltar que existem outros métodos de cálculo do equilíbrio líquido-vapor, como, por exemplo os métodos NRTL e UNIQUAC, os quais fazem uma melhor aproximação da mistura real entre o etanol e água. O Apêndice A apresenta as variáveis do processo no estado estacionário.

4.2. Análise dinâmica do processo de destilação

No processo de destilação estudado, a vazão de alimentação depende diretamente do processo anterior, não podendo então ser utilizada como variável manipulada. Desta forma, a razão de refluxo e a vazão molar de alimentação de vapor no refeedor são as possíveis variáveis manipuladas das torres de destilação. As Figuras 13 e 14 apresentam o efeito da razão de refluxo e da vazão molar de alimentação de vapor no refeedor sobre a variável controlada, respectivamente. As simulações foram feitas em ambiente MATLAB e o código do modelo das destilações (assim como o da fermentação) é apresentado no Anexo 1.

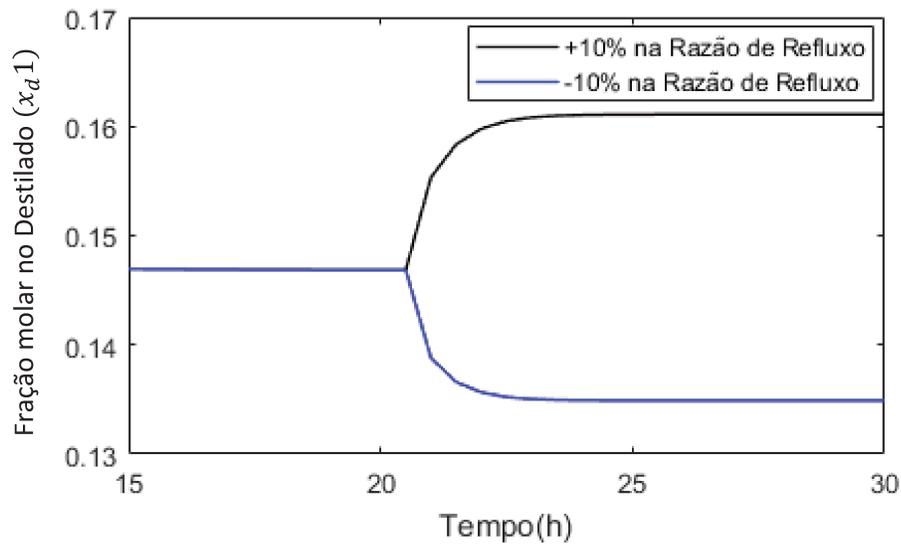


Figura 13: Efeito da razão de refluxo sobre a variável manipulada.

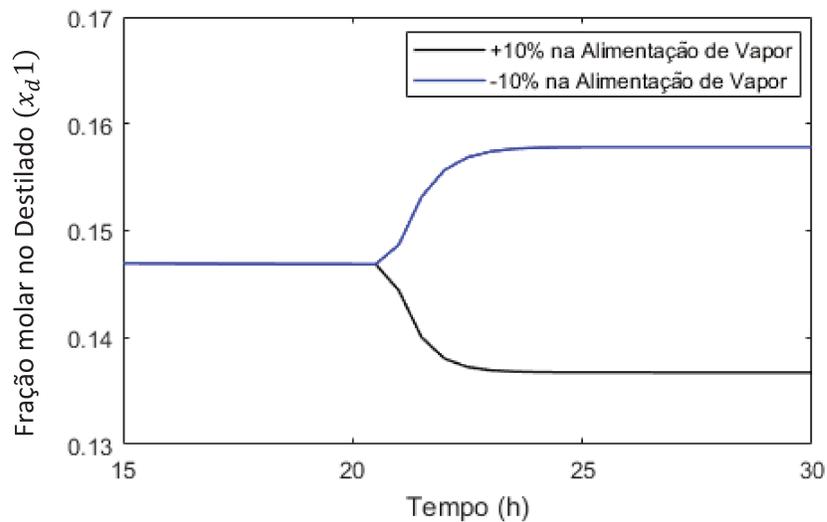


Figura 14: Efeito da vazão molar de alimentação de vapor no refeedor sobre a variável manipulada.

A razão de refluxo apresentou um ganho igual à 0,34, superior ao da alimentação de vapor que apresentou um ganho de 0,2, tendo assim maior influência sobre a variável controlada. Além disso, a razão de refluxo apresentou uma resposta mais rápida se comparada com a alimentação de vapor no refeedor, sendo assim escolhida como variável manipulada da primeira destilação. Como ambas as torres de destilação utilizam o mesmo modelo fenomenológico, a destilação 2 também utilizará a razão de refluxo como variável manipulada. Para analisar o efeito

da destilação 1 sobre a destilação 2, foi considerado um degrau de -60% na vazão do destilado (D1) da coluna 1 (Figura 15). A alteração em D1 foi feita de forma indireta pela razão de refluxo.

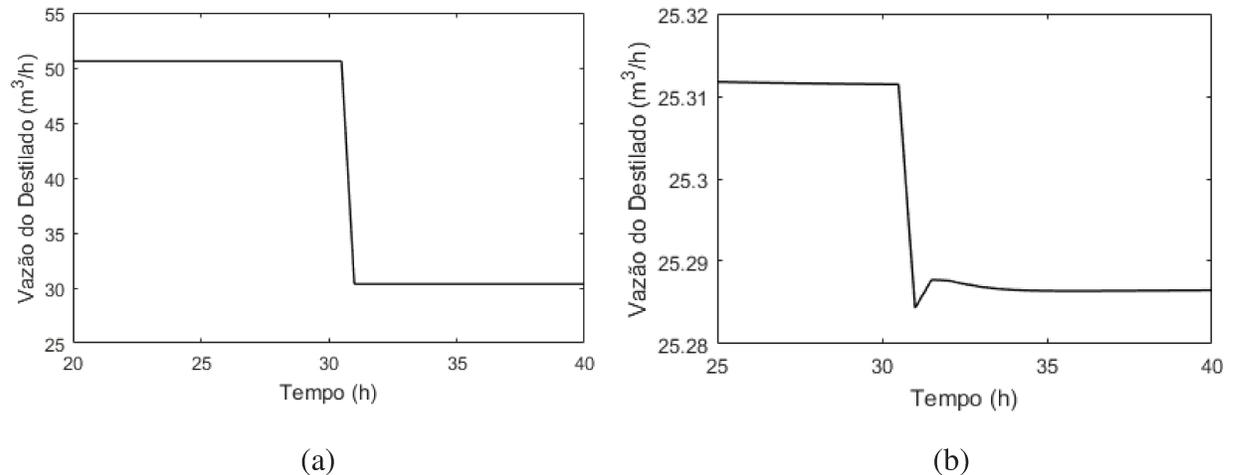


Figura 15: Perturbação degrau na vazão de destilado da coluna 1 (a) e seu efeito sobre a vazão do destilado na coluna 2 (b).

A Figura 15 mostra que uma mudança da vazão do destilado da coluna 1 gera uma mudança da vazão do destilado da coluna seguinte. Como consequência, a fração de etanol de saída de cada destilação também se altera, como mostra a Figura 16.

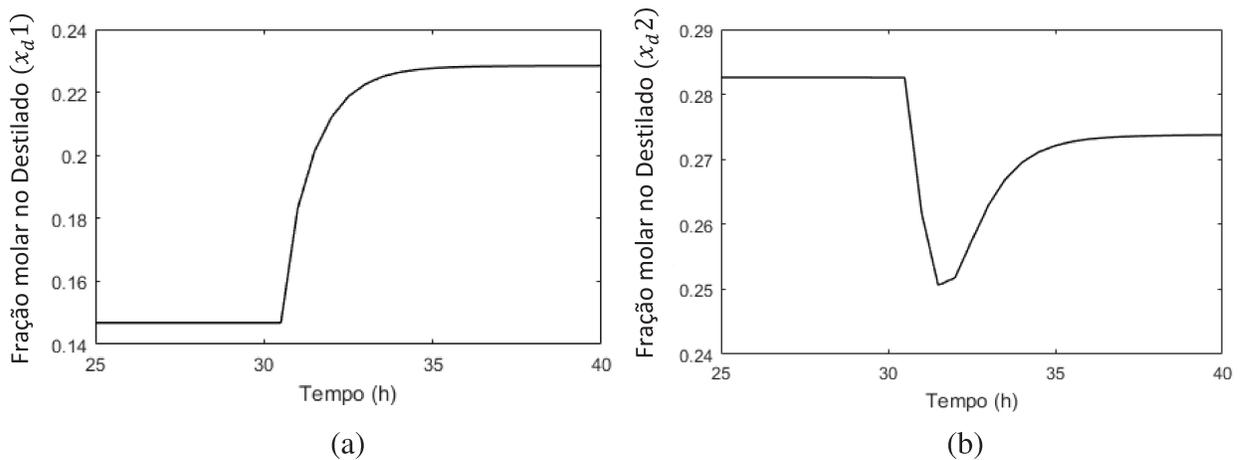


Figura 16: Efeito da mudança da vazão de destilado sobre a destilação 1 (a) e sobre a destilação 2 (b).

A atuação do controlador sobre a razão de refluxo da primeira destilação acarretará em uma mudança da vazão de destilado, tendo um efeito direto sobre o processo seguinte, o que mostra a necessidade de uma estratégia distribuída de controle.

4.3. Conclusões

Neste capítulo foi apresentado o modelo fenomenológico para os processos de destilação utilizados no estudo. A razão de refluxo foi escolhida como a variável manipulada para as duas colunas de destilação por ter uma maior influência sobre a concentração de etanol de saída. Além disso, uma análise dinâmica do processo foi apresentada para verificar a interação entre os processos e justificar a utilização de uma estratégia distribuída de controle.

4.4. Nomenclatura do modelo

h_D	Entalpia do produto de topo (KJ/mol)
σ	Constante hidráulica
n	Estágio da coluna de destilação
T	Temperatura (K)
H	Entalpia da fase vapor (KJ/mol)
D	Vazão do produto de topo (Kmol/h)
h	Entalpia da fase líquida (KJ/mol)
z_f	Fração de etanol na alimentação
y_n	Fração molar da fase vapor
x_n	Fração molar da fase líquida
V_v	Alimentação de vapor (utilidade) no refeedor(Kmol/h)
V_r	Vazão de vapor no estágio 1 (Kmol/h)
V_n	Vazão de vapor no estágio n (Kmol/h)
Q_c	Taxa de calor removida pelo condensador (KJ/(Kmol.h))
P^o	Pressão de vapor saturado (KPa)
M_n	Retido de líquido no estágio n (Kmol)
M_0	Retido inicial de cada estágio (Kmol)
L_n	Fluxo de líquido que escoo do estágio n (Kmol/h)

CAPÍTULO 5

5. CONTROLE MPC NO PROCESSO FERMENTATIVO

Este capítulo apresenta a implementação de um controle preditivo baseado em modelo neural em um processo de fermentação contínua descrito no Capítulo 3. Mostra-se também a metodologia utilizada para a implementação do MPC no sistema, além de apresentar a resposta do controlador quando sujeito aos problemas servo e regulador.

5.1. Introdução

A operação de fermentação está entre os processos que possuem maior dificuldade de operação e controle em uma indústria química. Desta forma, um controle eficiente se faz necessário para melhorar a resposta dinâmica do processo.

Para a implementação do controle MPC do processo fermentativo, seguiu-se algumas etapas essenciais. Primeiramente, escolheu-se quais as variáveis manipuladas, controladas e os distúrbios que influenciam o processo. A variável manipulada é a variável que o controlador utiliza para manter a variável controlada no valor de referência (*set-point*). Depois disso, na segunda etapa, analisou-se a dinâmica do processo através do modelo fenomenológico para identificar suas limitações operacionais. Estas limitações serão aplicadas à rotina de otimização do controlador.

A terceira etapa é a geração do modelo neural a partir do modelo fenomenológico, neste caso representando uma planta real. Este modelo neural deverá obedecer às restrições operacionais além de representar satisfatoriamente o processo. Por fim, a quarta etapa é a simulação da planta para a determinação e análise da “performance” do controlador MPC quando sujeito a perturbações, comparando-o com o controle PID.

5.2. Escolha das variáveis

No processo fermentativo descrito no capítulo 3 tem-se diversas variáveis de saída e de entrada que podem ser escolhidas como variáveis controladas e manipuladas. Porém, deve-se escolher variáveis que permitam um controle eficiente e que, quando se implementa o controle distribuído, precisa-se de variáveis que mais influenciam o processo como um todo.

A variável controlada escolhida foi a concentração de etanol no vinho deslevedurado (Figura 8) pois é o produto de interesse e de influencia diretamente o processo de destilação seguinte. A taxa de reciclo foi escolhida como variável manipulada por ter grande influência sobre a variável controlada escolhida. Já o distúrbio do processo fermentativo pode ser feito através da concentração de substrato na alimentação.

5.3. Limitações do processo

A definição das limitações do processo foi feita através da simulação, com variações da variável manipulada e nos distúrbios de forma a obter valores máximo e mínimos das variáveis de saída. A Tabela 4 mostra os valores máximos e mínimos para cada variável.

	Variável	Mínimo	Máximo
Varável Manipulada	Taxa de Reciclo	0.1	0.6
Variável Distúrbio	Concentração de Substrato (g/L)	170	190
Variável Controlada	Concentração de Etanol (g/L)	44.2	73.5

Tabela 4: Limites do processo de fermentação

Os limites apresentados na tabela 4 foram utilizados na simulação do processo, com um tempo de amostragem de 30 minutos. Os dados da simulação foram utilizados na obtenção do modelo neural. Vale ressaltar que as limitações obtidas foram baseadas nas simulações feitas a partir do modelo do processo, respeitando os limites operacionais.

5.4. Modelo neural da fermentação

Para a geração do modelo neural, utilizou-se os modelos do tipo NNARX (*Neural Nonlinear Auto Regressive Exogenous Inputs*), uma metodologia de geração de modelo de predição que utiliza os próprios dados de saída do sistema como entrada do treinamento da rede

neural. Os modelos NNARX são baseados em tempo discreto e utilizam valores passados de saída e de entrada para obter valores de saídas futuros (MELEIRO; VON ZUBEN; FILHO, 2009). Essencialmente, os dados de simulação foram utilizados para o treinamento da rede neural que, posteriormente, foi utilizada como modelo de predição no MPC do processo fermentativo. De forma genérica, a representação do modelo NNARX pode ser descrita como:

$$y(k+1) = f(y(k), y(k-1), \dots, y(k-n), u(k), u(k-1) \dots, u(k-n), d(k), d(k-1), \dots, d(k-n)) \quad (42)$$

onde y , u e d são a saída, a variável manipulada e a variável distúrbio respectivamente e k é o instante de tempo discreto. Para o processo fermentativo, podemos representar o modelo NNARX como mostra a equação 43:

$$P(k+1) = f(P(k), P(k-1), T_r(k), S_0(k)) \quad (43)$$

onde P é a concentração do etanol na saída do último fermentador, T_r é a taxa de refluxo, S_0 é a concentração de substrato na entrada e k é o instante de tempo discreto. Ou seja, a entrada do modelo neural será $P(k)$, $P(k-1)$, $T_r(k)$ e $S_0(k)$ e sua saída é o valor de concentração do substrato um instante de tempo futuro $P(k+1)$. Um esquema da rede neural é mostrado na Figura 17.

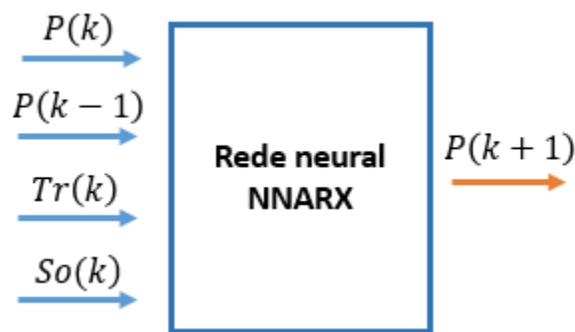


Figura 17: Esquema de rede neural do processo fermentativo.

Para o treinamento da rede, utilizou-se uma simulação do processo fermentativo durante dez mil horas de operação. As variáveis de entrada T_r e S_0 receberam variações randômicas em intervalos de tempo de 20 e 50 horas respectivamente. Este intervalo entre as perturbações se justifica pelo fato de o processo fermentativo estudado apresentar um tempo de acomodação de,

aproximadamente, 20 horas. As Figuras 18 e 19 mostram as mudanças feitas nas variáveis de entrada T_r e S_0 , enquanto a Figura 20 mostra o efeito dessas mudanças sobre variável de saída P .

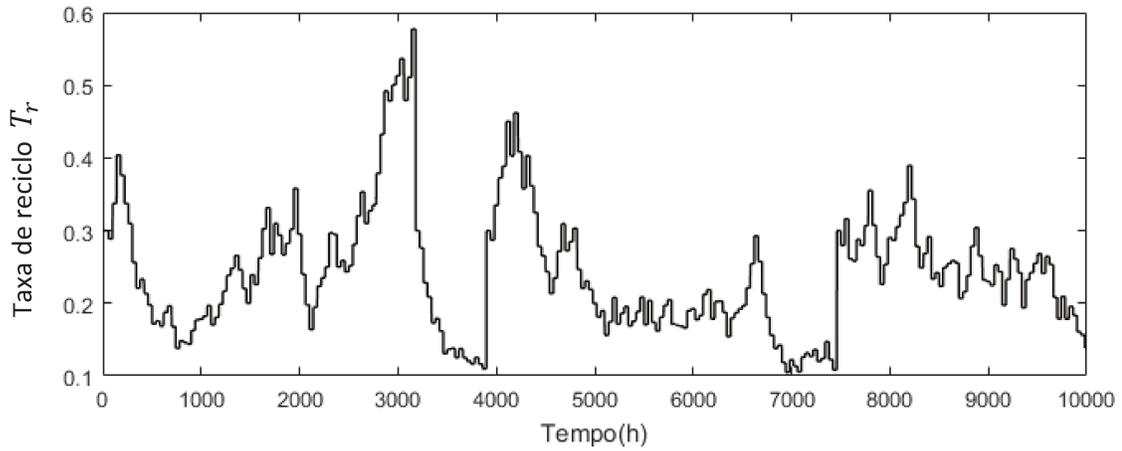


Figura 18: mudanças randômicas na taxa de reciclo (T_r).

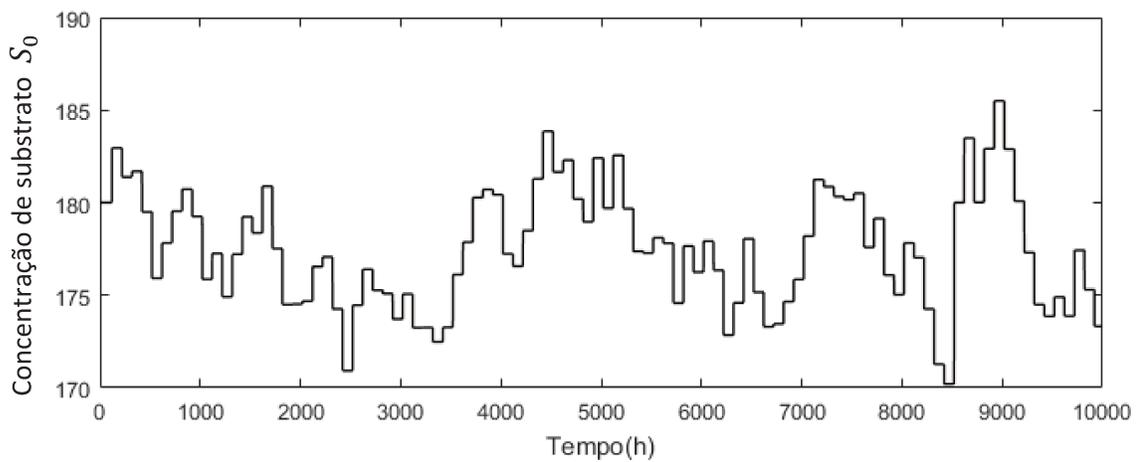


Figura 19: mudanças randômicas na concentração de substrato de entrada (S_0).

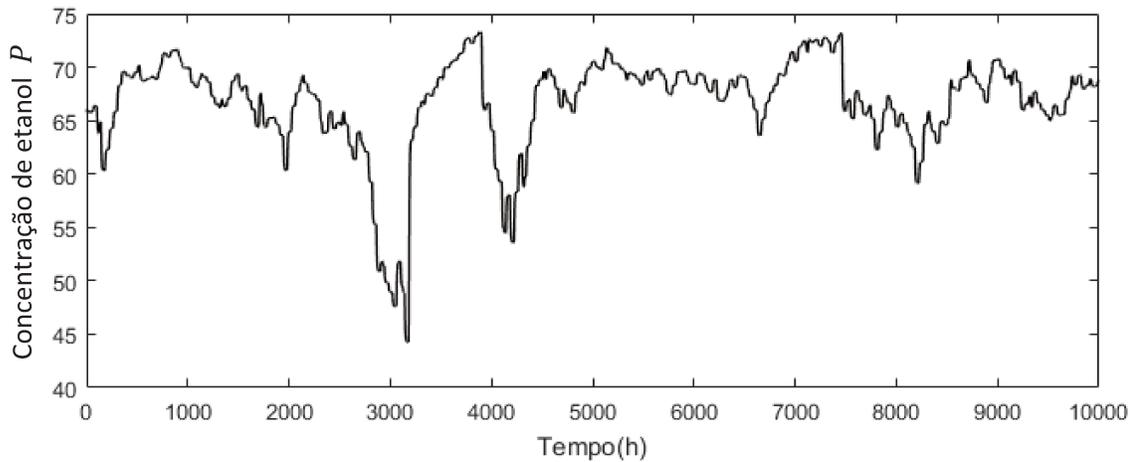


Figura 20: Saída P resultante das mudanças em S_0 e T_r .

Para o treinamento da rede *feedforward* do tipo NNARX, normalizou-se os dados acima para valores entre -1 e 1, de forma a melhorar o desempenho do treinamento da rede neural. A tabela abaixo mostra o parâmetro de “performance” pela média do quadrado dos erros MSE para diferentes números de neurônios na camada intermediária. No treinamento da rede foi utilizada a Regularização Bayssiana (com $\varepsilon = 0,005$) e o método de Levenberg-Maquardt (MORE, 1977). Dos dados simulados 70% para foi para o treino, 15% para o teste e 15% para a validação.

O número escolhido foi de 5 neurônios na cama intermediária, tendo em vista que acima disso a rede começa a apresentar característica de *overfitting*, o que aumenta o MSE e diminui o potencial de predição do modelo. A Figura 21 mostra o MSE para diferentes número e de neurônios.

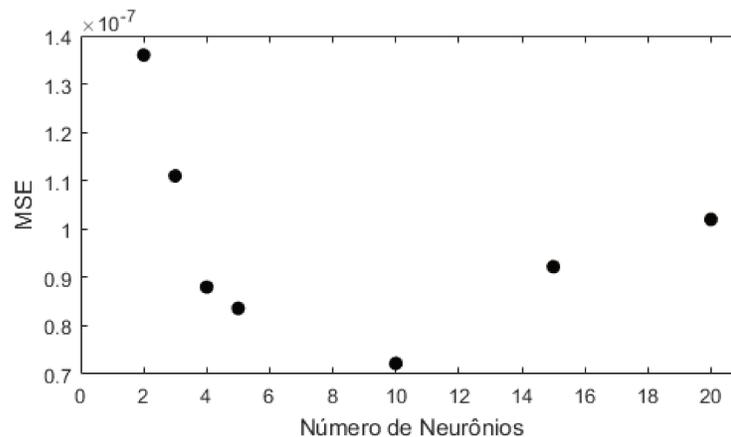


Figura 21: MSE para diferentes números de neurônios na camada intermediária.

De acordo com MELEIRO (2002), uma forma eficiente de analisar a rede neural do tipo NNARX é através da simulação recursiva. A Figura 22 mostra a simulação recursiva realizada em um intervalo de tempo de 500 horas para a rede treinada com 5 neurônios.

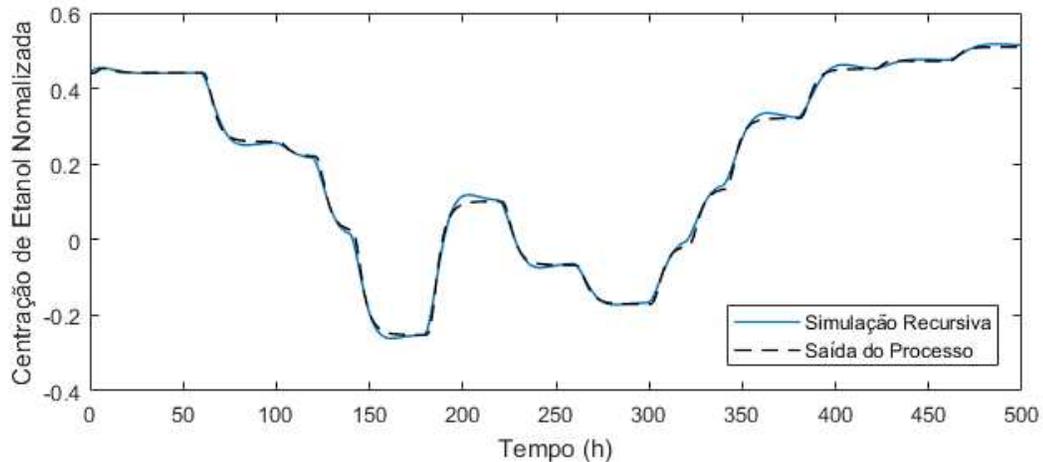


Figura 22: Simulação recursiva para a análise do modelo neural da fermentação.

A análise da simulação recursiva é importante para verificar a capacidade do modelo em prever a saída do processo utilizando apenas valores iniciais de entrada e a saída da rede como dados de simulação (MELEIRO, 2002). A Figura 22 mostra que a rede neural conseguiu fazer a predição da saída do processo em um tempo futuro de 500 horas, com um MSE de $7,14 \times 10^{-5}$, sendo suficiente para a utilização como modelo de predição no controle MPC.

5.5. Implementação do controlador no processo de fermentação

A implementação do controle preditivo foi feita utilizando o modelo neural obtido na seção 5.4. O modelo apresentou resultados satisfatórios na análise através da simulação recursiva e no critério de desempenho (MSE) durante o treinamento. A Figura 23 mostra um fluxograma da proposta de atuação do controle MPC no processo de fermentação.

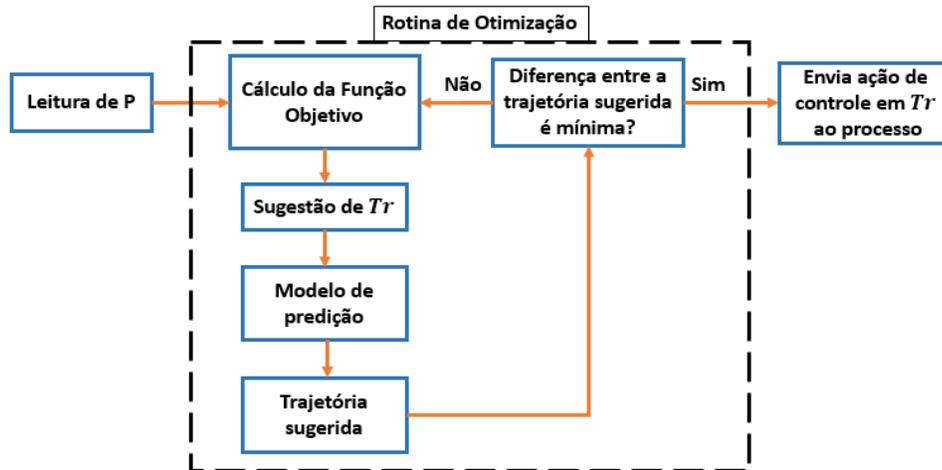


Figura 23: Esquema de funcionamento do controle preditivo baseado em modelo.

O controle se inicia com a leitura da variável de saída do processo, que é a concentração no vinho deslevedurado. Esta leitura é enviada à rotina de otimização, onde calcula-se o valor da função objetivo. Através de um valor inicial da variável manipulada T_r o modelo de predição gera uma trajetória em um intervalo de tempo futuro definido pelo horizonte de predição N_y . A trajetória sugerida é comparada com o *set-point* e a procura de valores de T_r continua até que esta diferença entre elas seja mínima. O método de busca utilizado no MPC foi o método do ponto interior. Com isso, a primeira ação de controle encontrada pela rotina de otimização é enviada ao processo.

Esta ação se repetirá a cada instante de tempo, aplicando assim o horizonte de móvel ao processo (CHRISTOFIDES; SCATTOLINI; MU, 2013). O tamanho da trajetória sugerida (Figura 18) é dado pelo parâmetro chamado de horizonte de predição (N_y), o qual deve ser escolhido de acordo com dinâmica do processo. Em outras palavras, o horizonte de predição especificará quando tempo no futuro que o modelo de predição irá simular recursivamente o processo. A função objetivo controlador MPC para a fermentação é representada pela equação 44.

$$\min J(u) = \alpha \sum_{i=1}^{N_y} (P'_{k+i} - set)^2 + \beta \sum_{i=1}^{N_u} (\Delta T_r)^2 \quad (44)$$

sujeito à:

$$0.1 < T_r < 0.6$$

A Figura 24 mostra o comportamento da resposta do processo fermentativo e das ações do controlador para diferentes valores de N_y .

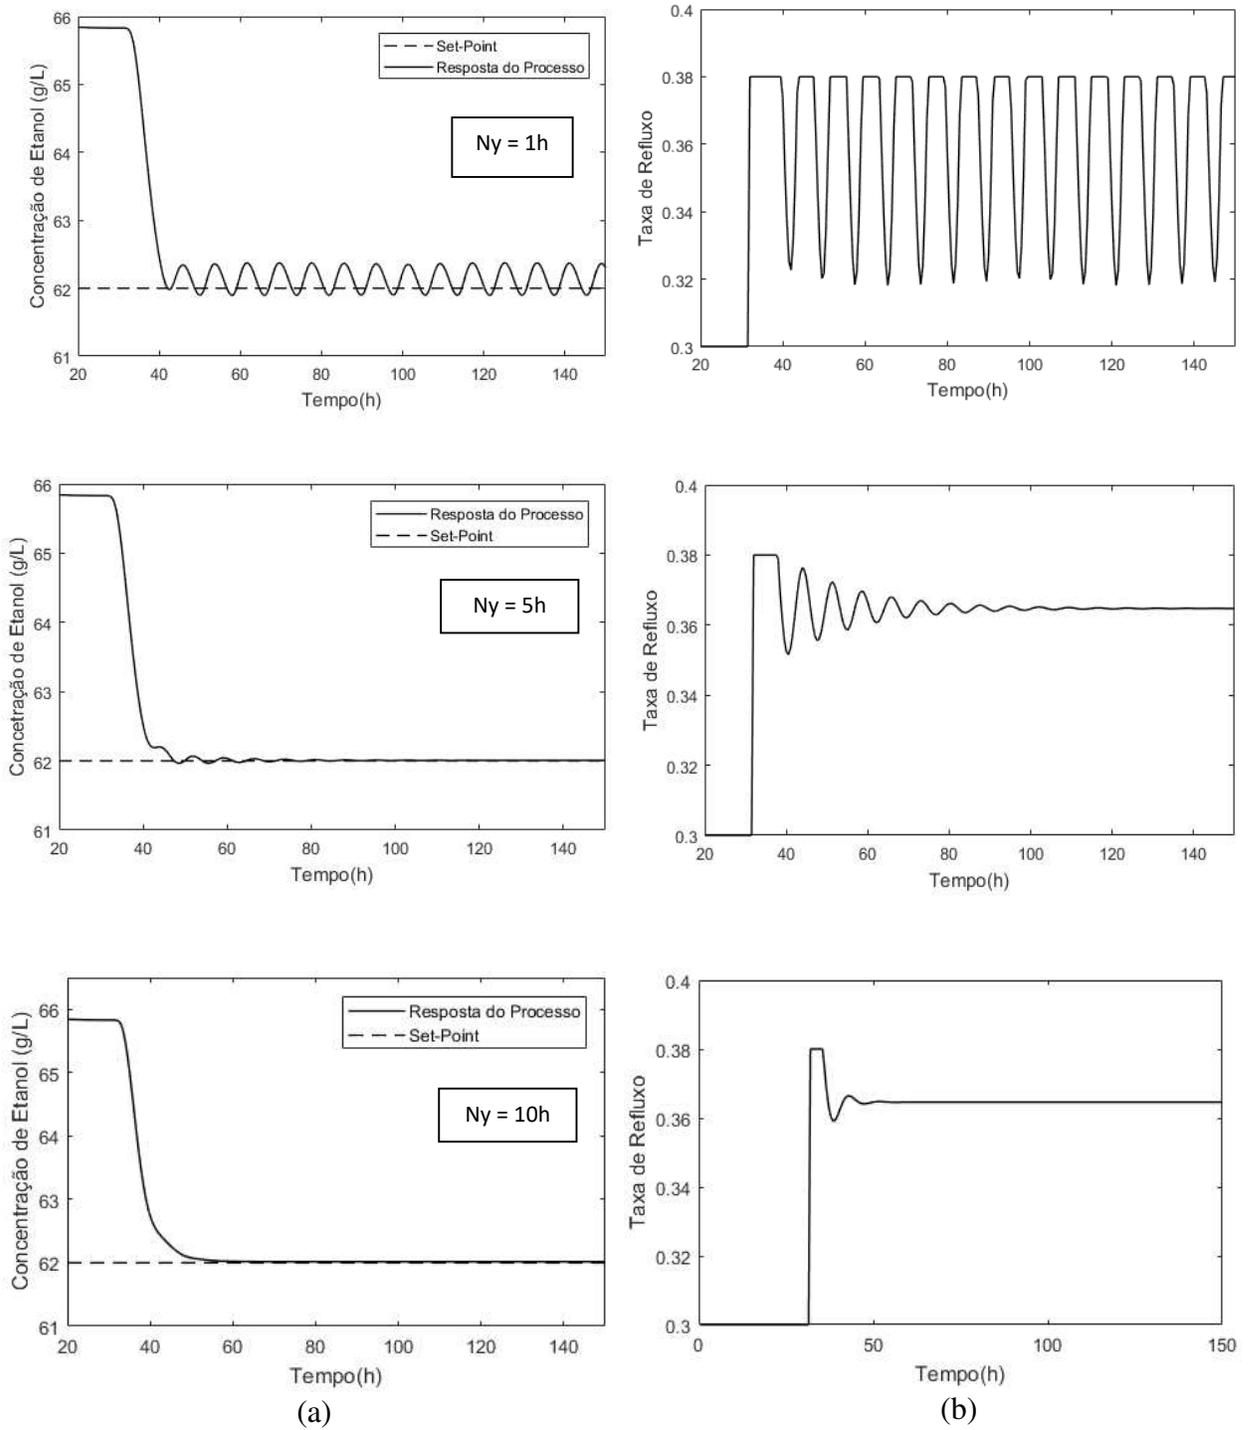


Figura 24: Resposta do sistema (a) e ação de controle na taxa de refluxo (b) para diferentes valores de horizonte de predição (N_y).

A Figura 24 mostra que para valores de N_y inferiores a 5, o sistema se torna cada vez mais oscilatório e atinge a instabilidade quando N_y é menor ou igual a 2. O valor ideal para ser utilizado no horizonte de predição é a partir de 10 por ter um menor tempo de acomodação e menor atuação na variável manipulada. Isso ocorre porque a dinâmica do processo fermentativo é lenta, sendo necessário uma predição maior no tempo. Valores superiores de 20 para o horizonte de predição passam a ter uma resposta parecida, porém, à medida que se aumenta N_y , aumenta também o esforço computacional, sendo assim o valor de N_y entre 10 e 20 mais indicados para este processo.

Outro parâmetro a ser sintonizado no MPC é o horizonte de controle N_u . Este parâmetro define quantos valores futuros da variável manipulada serão sugeridos pelo otimizador de forma a encontrar a trajetória ótima do sistema. Portanto, quando maior o valor de N_u , maior o número de variáveis a ser otimizada, conseqüentemente, maior a complexidade e esforço computacional para atingir o valor ótimo. A Figura 25 mostra a resposta do sistema para diferentes valores de horizonte de controle N_u .

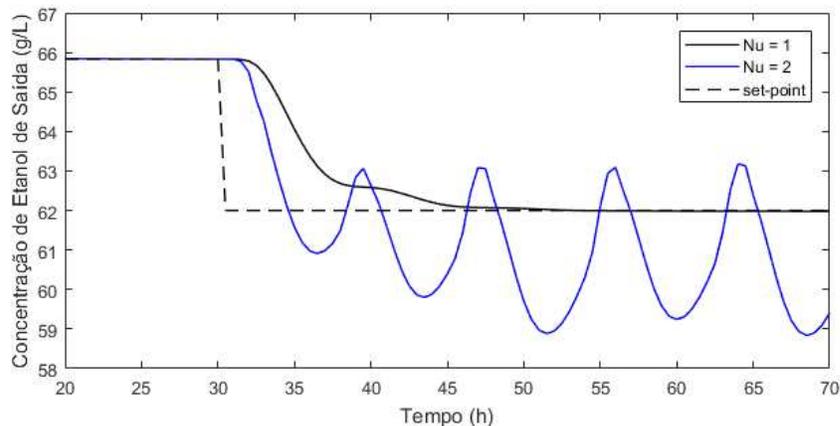


Figura 25: Efeito do horizonte de predição no controle MPC da fermentação.

Para de N_u acima de 1, a ação de controle torna a saída do processo instável. Isto ocorre porque o treinamento da rede não conseguiu prever mudanças a cada instante de tempo na variável manipulada, mas apenas mudanças degrau com um intervalo de tempo de 20 horas. Sendo assim, o horizonte de controle utilizado para o processo de fermentação foi igual à 1.

Esta análise foi feita com a aplicação da ação de controle em cada instante de amostragem do processo (30 min). Entretanto, deve-se procurar reduzir ao máximo as ações do

controlador para evitar desgastes de equipamentos. A Figura 26 mostra a resposta para a ação do controlador MPC discretizado em diferentes intervalos de tempo d .

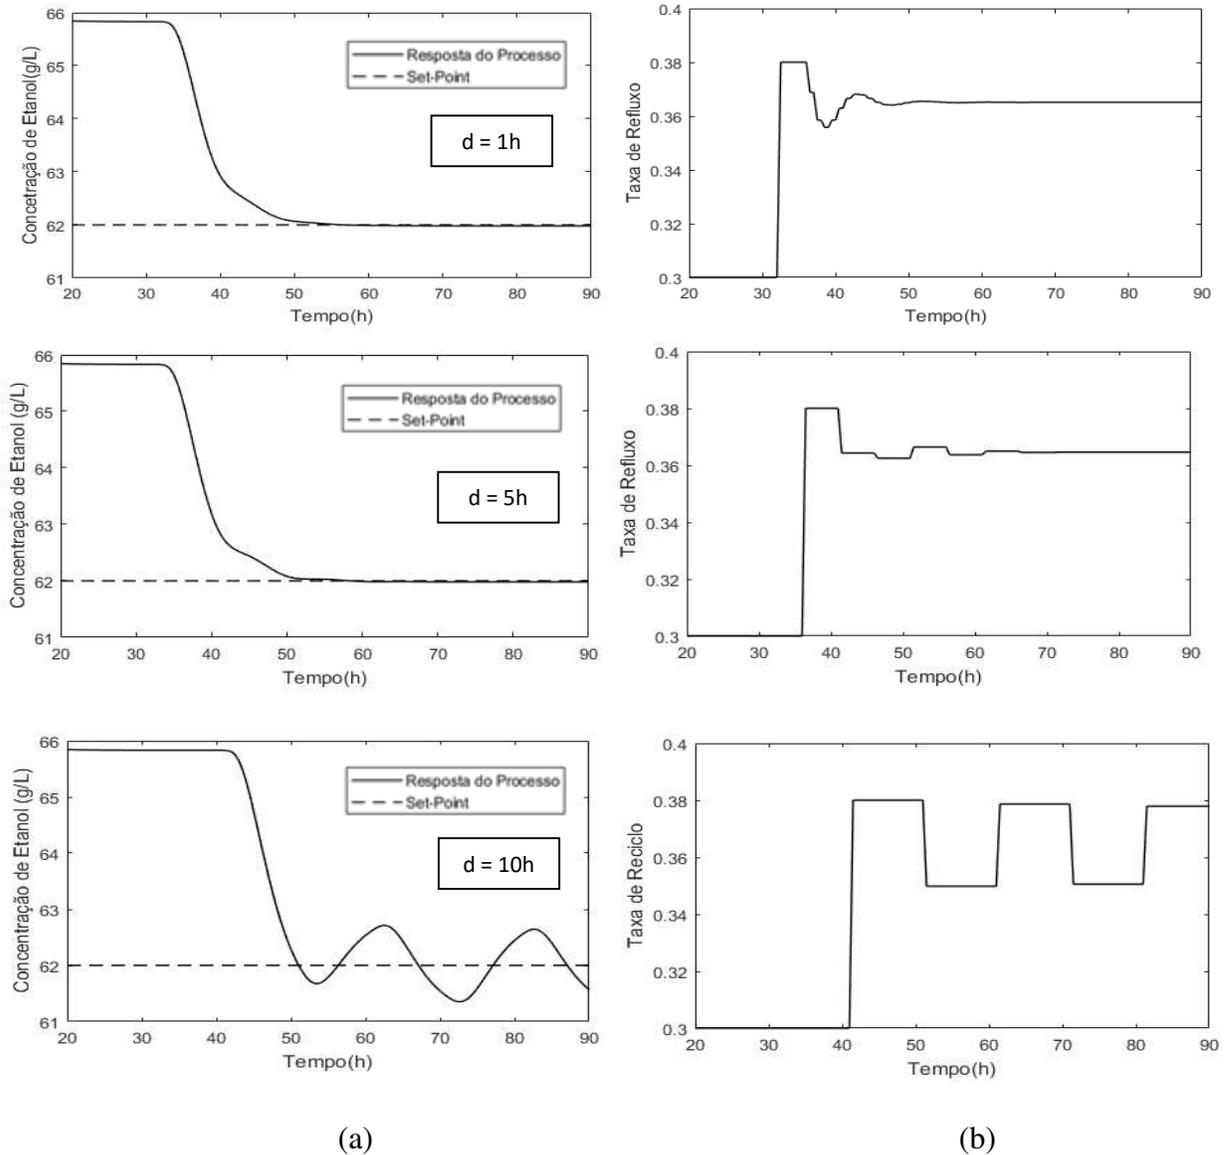


Figura 26: Resposta do sistema (a) e ação de controle na taxa de refluxo (b) para diferentes intervalos de discretização na ação do controlador.

A Figura 26 mostra que ao se usar um intervalo de discretização acima de 10h, a resposta do sistema se torna instável. Para valores entre 1 e 5 horas, o sistema ficou estável e conseguiu atingir o *set-point*. Porém, para uma melhor margem de segurança na estabilidade do processo, será utilizada uma discretização de 1 hora na ação do controlador. Portanto, a configuração escolhida para o controlador MPC do processo fermentativo é mostrada na Tabela 5.

Horizonte de predição (N_y)	10h
Horizonte de controle (N_u)	1
Intervalo de discretização	1h
Penalização pelo erro (α)	1
Penalização pela ação de controle (β)	0,001

Tabela 5: Configuração do MPC para o processo fermentativo.

Para comparar com o controle MPC, implementou-se o controlador Proporcional-Integral-Derivativo ao processo fermentativo. Com o erro $e(t)$ sendo a diferença entre a variável controlada e o *set-point*, a representação da ação de controle na sua forma contínua pode ser dada pela equação 45.

$$a\tilde{c}\tilde{a}\tilde{o}PID = K_p \left(e(t) + \frac{1}{K_i} \int_{-\infty}^0 e(t) dt + K_d \frac{de(t)}{dt} \right) \quad (45)$$

onde K_p , K_i e K_d são as constantes proporcional, integral e derivativa do controle PID, respectivamente.

Para a implementação no modelo, foi utilizado a forma digital do controle PID. Esta forma pode ser expressa pela equação 46.

$$a\tilde{c}\tilde{a}\tilde{o}PID = K_p \left(e(k) + \frac{1}{K_i} \sum_{k-ti}^k e(k) \cdot d + K_d \frac{e(k-1) + e(k)}{d} \right) \quad (46)$$

onde k é o instante de tempo discreto, d é o período de discretização e ti é o tempo de integração. Para a sintonia dos parâmetros do controlador, utilizou-se o método do ganho crítico de Ziegler-Nichols. Primeiramente desligou-se a ação integral e derivativa do controlador e aumentou-se o ganho K_p do processo em malha fechada até que se atingisse a instabilidade mostrada na Figura 27.

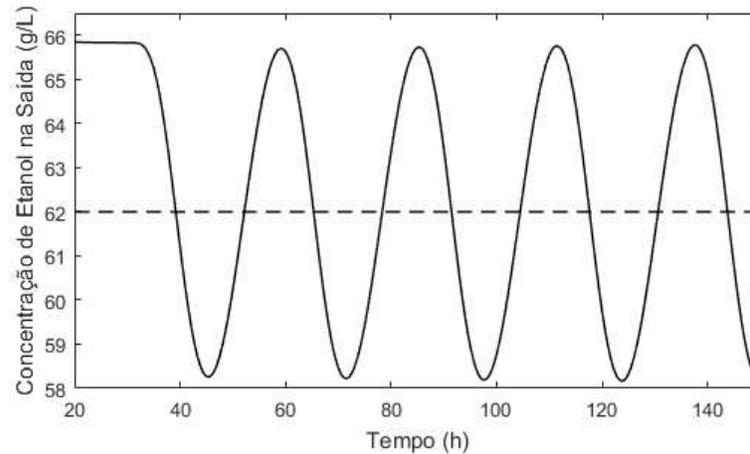


Figura 27: Determinação do ganho crítico do processo fermentativo.

O sistema atingiu comportamento oscilatório quando $K_p = K_c = 0,0029$. O período crítico do sistema em malha fechada foi $P_c = 26h$. A determinação dos parâmetros do controlador é dada pela Tabela 6.

Controlador	K_p	K_i	K_d
P	$0,5K_c$	∞	0
PI	$0,45K_c$	$(1/1,2)P_c$	0
PID	$0,6K_c$	$0,5P_c$	$0,125P_c$

Tabela 6: Sintonia dos parâmetros do controlador.

Com a aplicação do método de Ziegler-Nichols, obteve-se os ganhos do controlador onde $K_p = 0,0012$, $K_i = 20$ e $K_d = 2$. Vale ressaltar que este método oferece uma estimativa inicial dos valores, os quais foram alterados de forma a se obter uma resposta mais satisfatória para o controle PID. A Figura 28 mostra a comparação entre o controle MPC e PID para um problema servo, onde se alterou o *set-point* do processo de 65,8 para 62 g/L no instante $t = 30h$. A Figura 29 apresenta a resposta do processo para um problema regulador, fazendo alteração na variável distúrbio $S_0 = 190, 165, 185$ nos instante de tempo $t = 30, 150$ e $300h$ respectivamente.

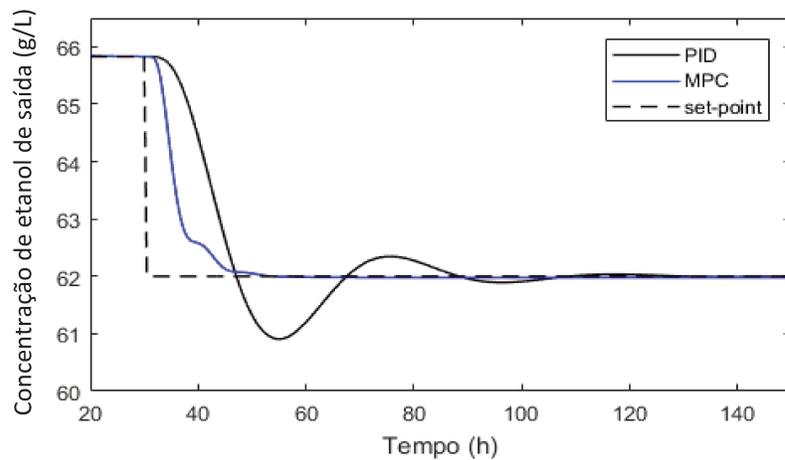


Figura 28: Comparação entre o controle MPC e PID para o processo fermentativo com problema servo.

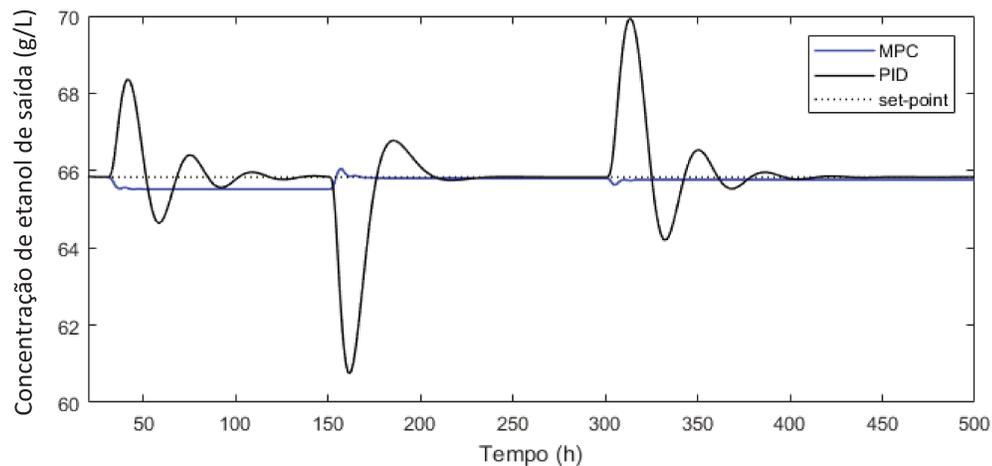


Figura 29: Comparação entre o controle MPC e PID para o processo fermentativo para o problema regulador.

As Figuras 28 e 29 mostram que o controle MPC apresentou uma melhor performance se comparado com o PID. O controle MPC apresentou um tempo de acomodação de 20 horas, enquanto o PID levou em média 90 horas para atingir o novo estado estacionário. Além disso, o sobressinal máximo para o problema regulador do MPC foi de 0,2, enquanto para o PID ficou entre 2 e 5. Entretanto, na primeira perturbação do problema regulador (Figura 29) houve um pequeno desvio do *set-point* de 0,12. Este desvio ocorreu devido à uma possível “fragilidade” do modelo de predição para este ponto de operação em específico, o que pode ser resolvido com o retreinamento da rede neural.

5.6. Conclusões

Este capítulo apresentou a metodologia de implementação, configuração e sintonia dos controladores MPC e PID para o processo de fermentação, bem como o treinamento do modelo de predição do controlador MPC. Na comparação entre as performances do PID e do MPC, o MPC apresentou um melhor desempenho em malha fechada para o processo fermentativo. No próximo capítulo será apresentado o controlador para o sistema de destilação.

Capítulo 6

6. CONTROLE MPC NO PROCESSO DE DESTILAÇÃO

6.1. Introdução

O processo de destilação está entre os processos industriais que mais consomem utilidades como a energia térmica na forma de vapor para o funcionamento do refeedor, bem como energia utilizada no resfriamento do fluido do condensador. Portanto, é essencial um controle que supra as necessidades operacionais, mantendo o consumo mínimo de utilidades possível e máxima estabilidade do sistema.

De forma análoga à implementação do MPC na fermentação, na destilação também se seguiu as quatro etapas: escolha das variáveis manipuladas, controladas e variáveis distúrbio; identificação das limitações operacionais; obtenção do modelo neural e configuração do controlador. O processo de destilação da planta estudada é composto por duas torres de destilação, onde o produto de topo da primeira destilação alimenta a segunda coluna de destilação, tal como descrito no Capítulo 4.

6.2. Escolha das variáveis

Como variável controlada foi escolhida a fração de etanol na saída de topo x_d (vol./vol.) em ambas as destilações. A razão de refluxo RR dada pela equação 47 foi escolhida como variável manipulada, pois possui influência direta com a variável controlada.

$$RR = \frac{Lr}{D} \quad (47)$$

onde Lr é a vazão de refluxo e D é a vazão de destilado. Como variável distúrbio da primeira destilação, foi utilizada a fração de etanol de entrada e a vazão de alimentação. A segunda destilação, por sua vez, tem como variáveis distúrbio a fração etanol de alimentação e a vazão do destilado D da primeira coluna.

6.3. Limitações do processo

A definição das limitações do processo ocorreu através da simulação do modelo fenomenológico, com variações da variável manipulada e nos distúrbios de forma a obter valores máximo e mínimos das variáveis de saída, assim como feito no processo de fermentação. Assim como no processo de fermentação, as limitações do processo foram baseadas nas simulações do processo e nas perturbações randômicas feitas para se determinar o *range* de operação de ambas as colunas de destilação

	Variável	Mínimo	Máximo
Varável Manipulada	Razão de Refluxo RR	0.1	0.9
Variável Distúrbio 1	Fração de etanol na alimentação z_1	0.052	0.073
Variável Distúrbio 2	Vazão de alimentação (m^3/h)	100	170
Variável Controlada	Fração de etanol saída x_d	0.07	0.52

Tabela 7: limites do processo para a coluna de destilação 1.

	Variável	Mínimo	Máximo
Varável Manipulada	Razão de Refluxo RR	0.1	0.9
Variável Distúrbio 1	Fração de etanol na alimentação z_2	0.1	0.52
Variável Distúrbio 2	Vazão de alimentação (m^3/h)	12.2	86.6
Variável Controlada	Fração de etanol na saída x_d	0.12	0.92

Tabela 8: limites do processo para a coluna de destilação 2.

Os valores das limitações das variáveis para as duas colunas de destilação estão apresentados nas Tabelas 7 e 8. Estes valores foram obtidos na simulação do processo durante 10000 horas, com um tempo de amostragem 30 minutos, assim como na fermentação. Na coluna 1 as variações concentração de etanol na alimentação x_d e vazão de alimentação são oriundas dos distúrbios ocorridos na fermentação. Assim como a fração de alimentação e a vazão de alimentação da coluna 2 são consequências das variações ocorridas na destilação 1.

6.4. Modelo neural da destilação

Assim como na fermentação, o modelo neural implementado para o processo de destilação foi o modelo NNARX. Os dados usados no treinamento da rede neural da destilação 1 estão apresentados nas Figuras 30 a 33 e os dados da destilação 2 são mostrados nas Figuras 34 a 37. As perturbações foram geradas de forma randômica a cada 8 horas nas variáveis manipuladas e 10 horas nas variáveis distúrbio. A diferença na frequência das mudanças ocorre devido à necessidade de não sobrepor as respostas resultantes dessas alterações.

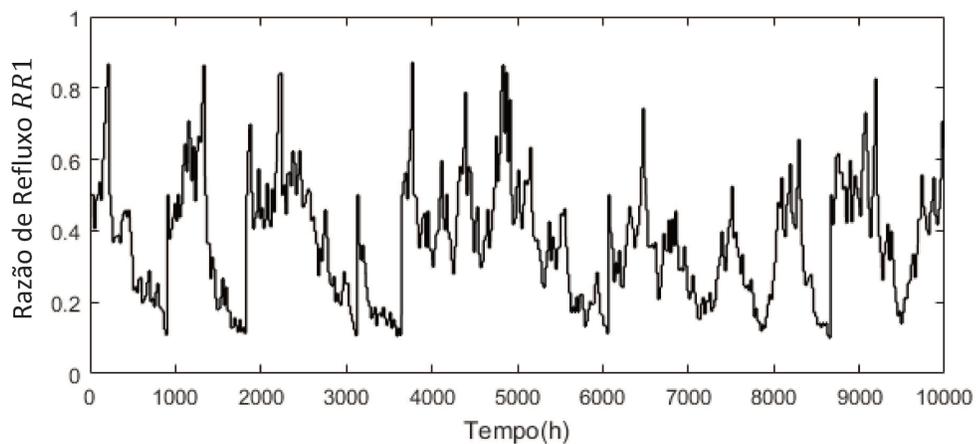


Figura 30: perturbações randômicas na razão de refluxo para a destilação 1

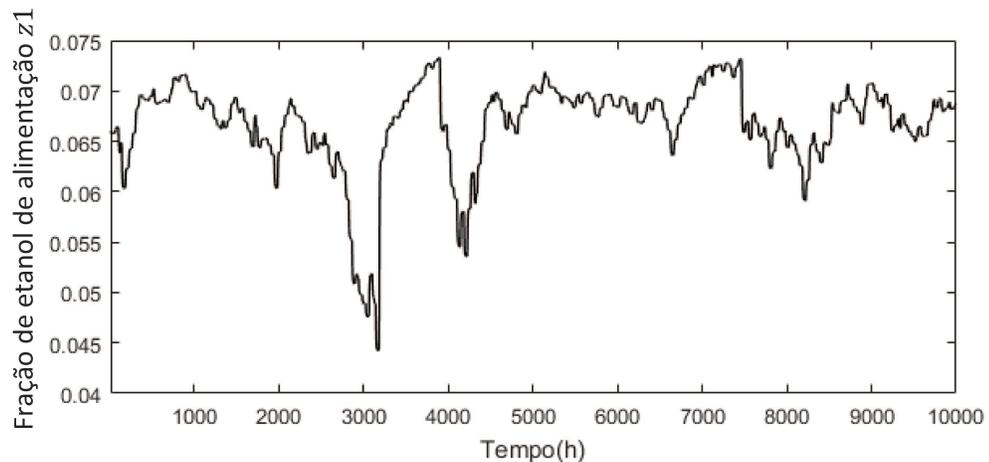


Figura 31: Variações da fração de etanol na alimentação da destilação 1.

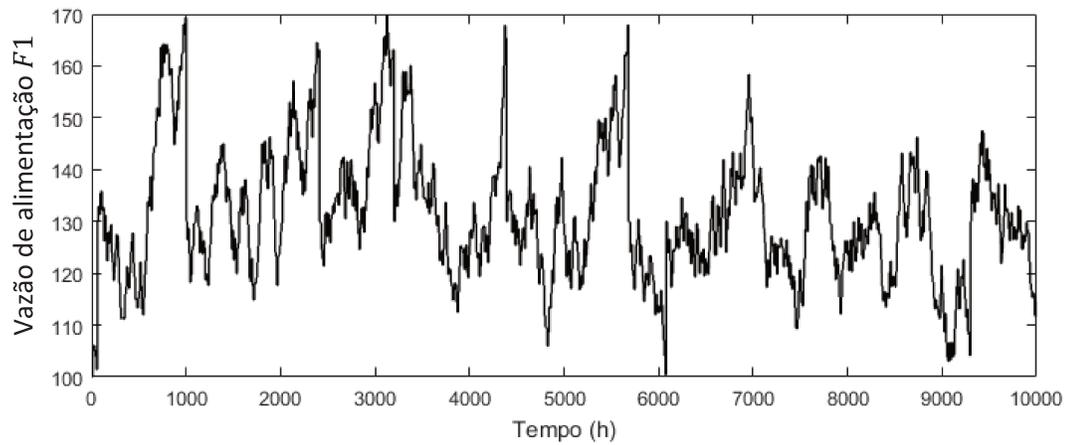


Figura 32: Variação na vazão de alimentação de destilação 2.

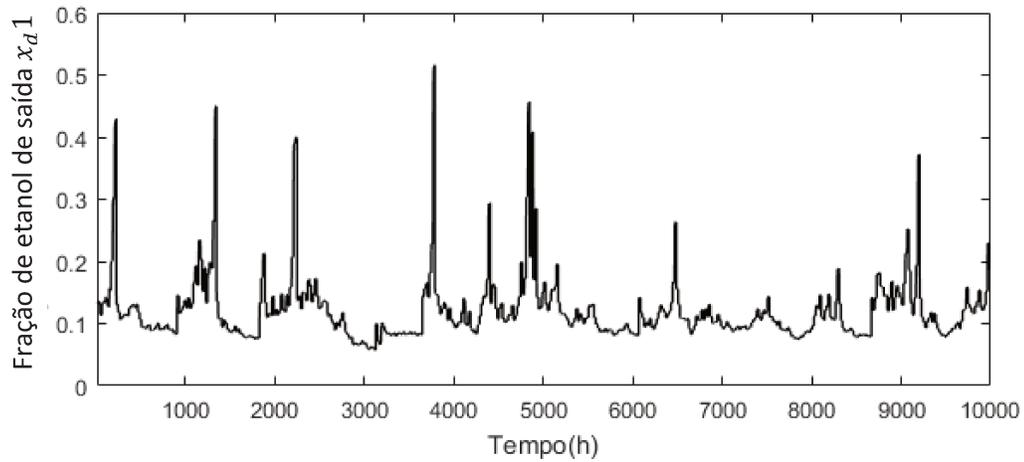


Figura 33: Resposta do sistema na fração de etanol de saída às perturbações randômicas.

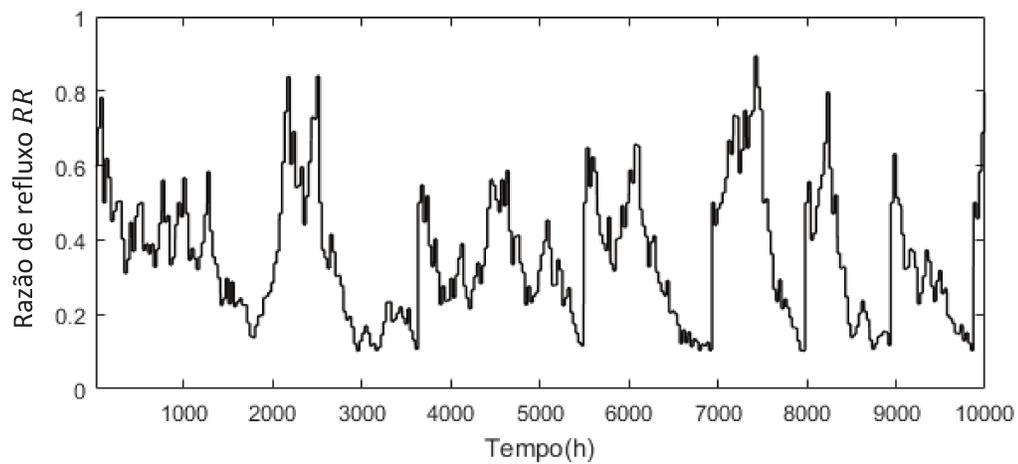


Figura 34: perturbações randômicas na razão de refluxo para a destilação 2.

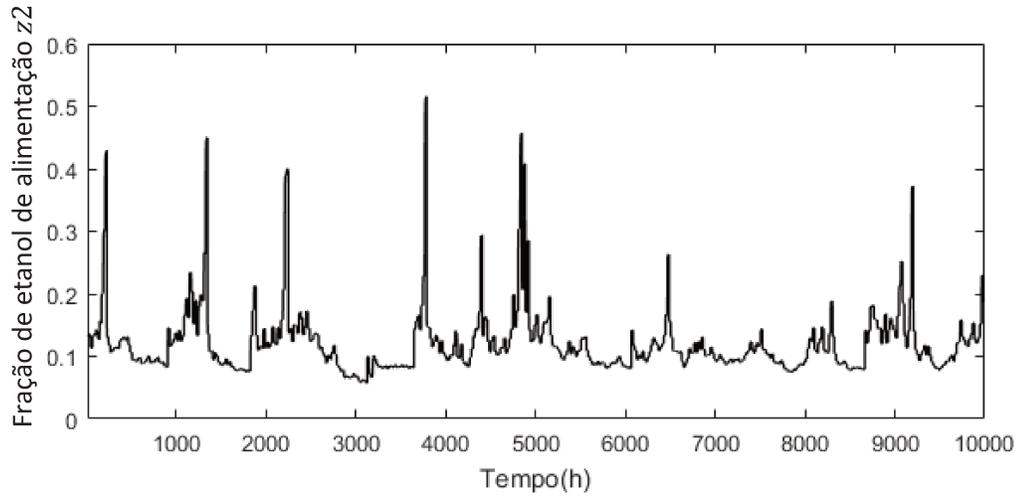


Figura 35: Variações da fração de etanol na alimentação da destilação 2.

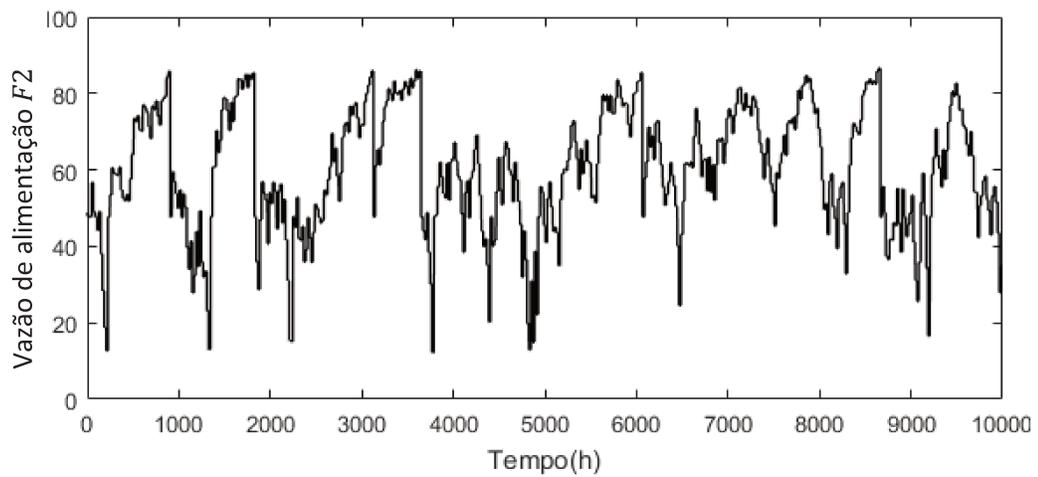


Figura 36: Variação na vazão de alimentação de destilação 2.

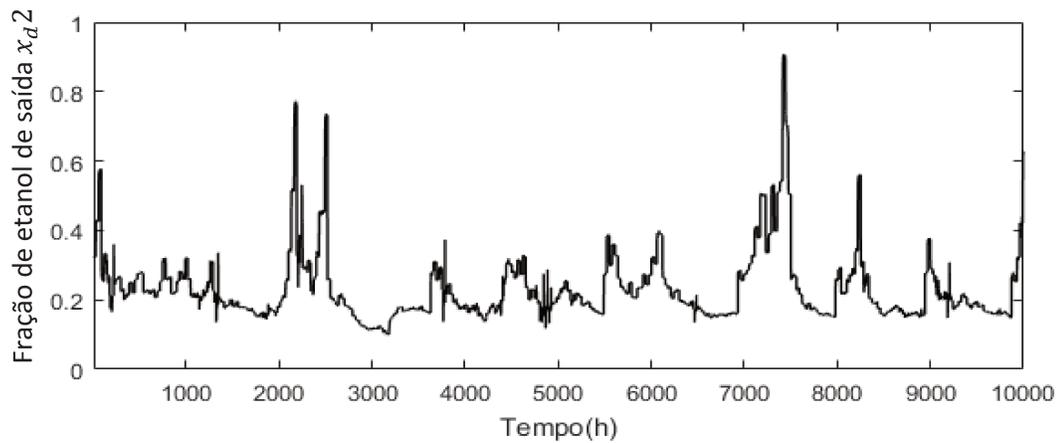


Figura 37: Resposta do sistema na fração de etanol de saída às perturbações randômicas.

Com os dados anteriormente mostrados treinou-se as redes neurais referentes a cada uma das colunas de destilação e a Figura 37 mostra o MSE quando se aumenta o número de neurônios. Como critério de performance utilizou-se o MSE e 20% dos dados apresentados foram utilizados para o teste de validação das redes neurais.

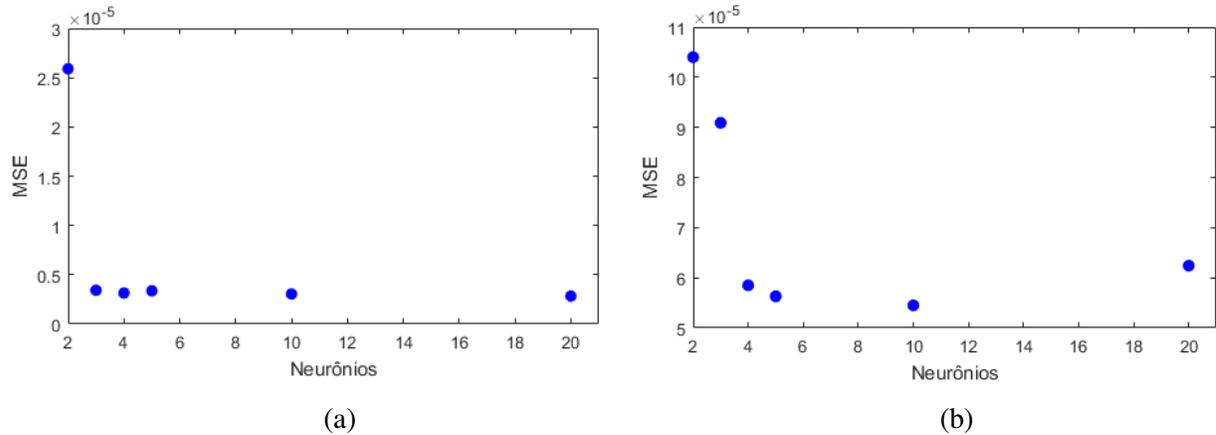


Figura 38: Relação entre o número de neurônios e MSE para a destilação 1 (a) e 2 (b).

Para ambas as destilações, utilizou-se 5 neurônios, onde se obteve valores de MSE inferiores a 10^{-5} além de não apresentar *overfitting*. A simulação recursiva de ambos os processos é mostrada na Figura 38 para a destilação 1 e na Figura 39 para a destilação 2.

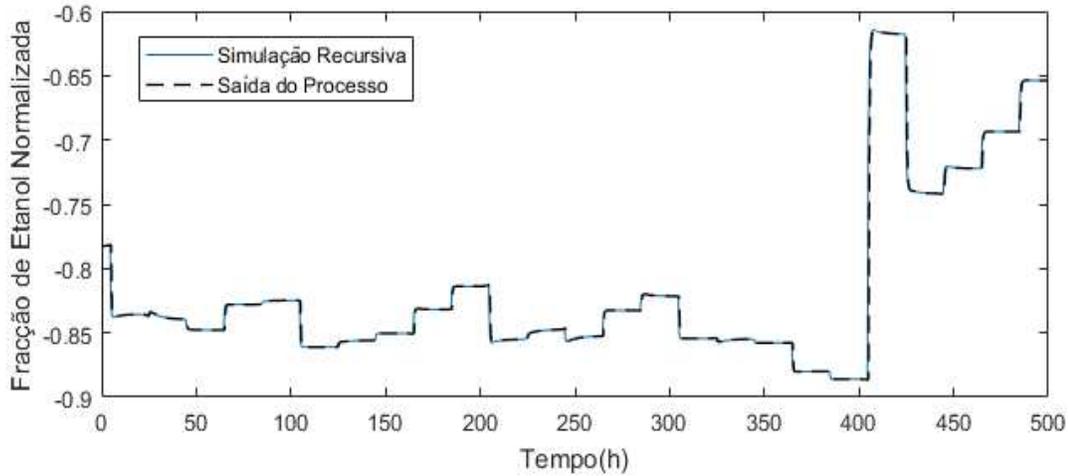


Figura 39: Simulação recursiva para a destilação 1

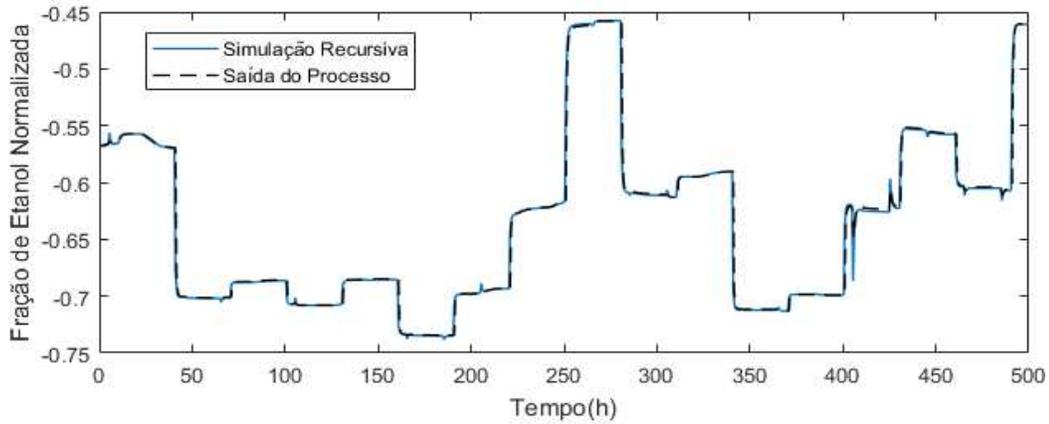


Figura 40: Simulação recursiva para a destilação 2

As Figuras 38 e 39 mostram que as redes neurais predizem de forma satisfatória tanto dinâmica da destilação 1 como a da destilação 2, apresentando um MSE inferior à 10^{-5} para a simulação recursiva. Desta forma, os modelos de predição foram capazes de prever de forma satisfatória ambos os processos de destilação e foram utilizados nos controladores MPC.

6.5. Implementação do controlador no processo de destilação

A equação 48 mostra o problema de otimização do controlador MPC para a destilação 1, enquanto a equação 49 representa o mesmo problema para a destilação 2.

$$\min J(u) = \alpha \sum_{i=1}^{N_y} (x_d 1'_{k+i} - set)^2 + \beta \sum_{i=1}^{N_u} (\Delta RR1)^2 \quad (48)$$

sujeito à:

$$0,1 < RR1 < 0,9$$

$$\min J(u) = \alpha \sum_{i=1}^{N_y} (x_d z'_{k+i} - set)^2 + \beta \sum_{i=1}^{N_u} (\Delta RR2)^2 \quad (49)$$

sujeito à:

$$0.1 < RR2 < 0.9$$

Após a implementação do controle MPC na destilação, analisou-se o efeito do horizonte de predição N_y no comportamento em malha fechada. A Figura 40 apresenta o efeito do horizonte de predição sobre a coluna de destilação 1.

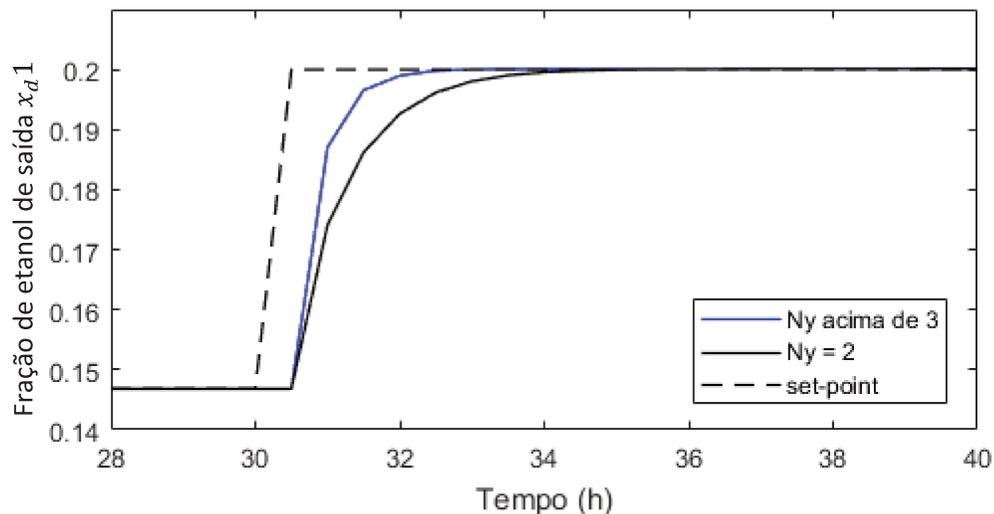


Figura 41: Efeito do horizonte de predição sobre a destilação 1.

Para um horizonte de predição igual à 2, o processo atingiu o estacionário sem oscilação, tendo uma resposta satisfatória. Para $N_y = 3$, o processo teve um menor tempo de acomodação, atingindo o estado estacionário mais rapidamente. Para valores acima de 3, não houve mudança no horizonte de predição do sistema. Sendo assim o valor definido de N_y para a destilação 1 foi de 3. A Figura 41 apresenta o efeito do horizonte de controle N_u para a destilação 1:

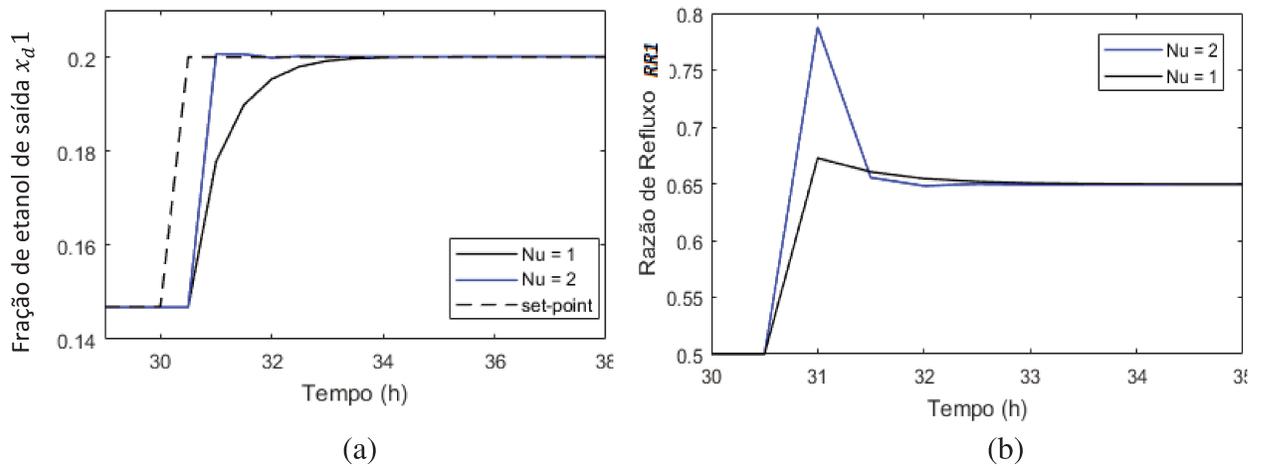


Figura 42: Efeito da do horizonte de controle sobre a destilação 1 (a) e sua respectiva ação de controle (b).

A Figura 41 mostra que para $N_u = 2$ o processo atinge o estacionário de forma mais rápida se comparado ao horizonte de controle de valor 1. Para valores acima de $N_u = 2$ não gera efeitos significativos na dinâmica do processo, sendo assim o valor 2 escolhido para esta variável.

O controlador também foi testado para diferentes intervalos de discretização, onde a ação do controlador foi instanciada em intervalos de discretização de $d = 0.5, 1$ e $2h$. O efeito da discretização é mostrado na Figura 42 e a ação de controle sobre a variável manipulada é mostrada na Figura 43.

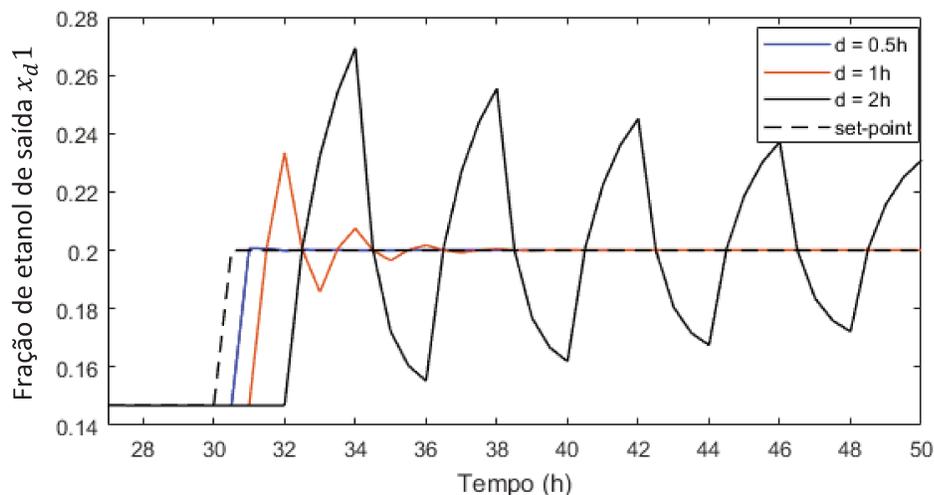


Figura 43: Efeito de diferentes valores de discretização sobre a dinâmica da destilação 1

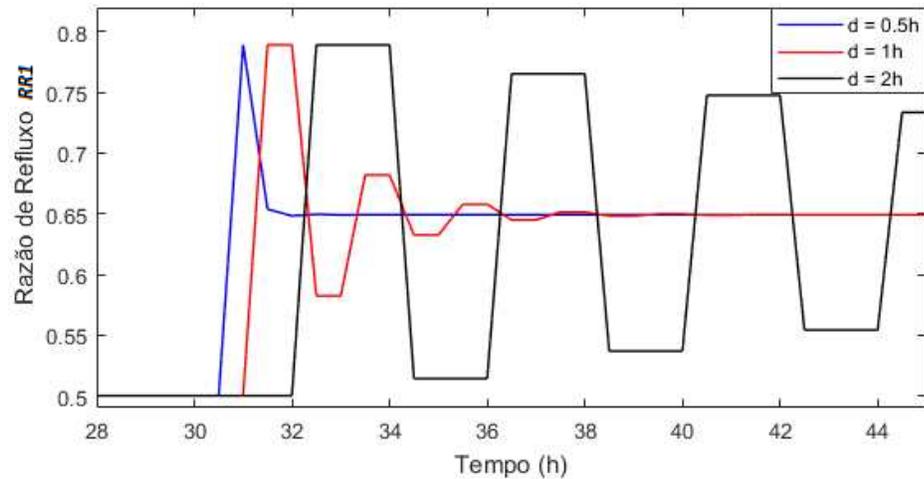


Figura 44: Ação de controle sobre a variável manipulada para diferentes valores de discretização.

A Figura 42 mostra que, para valores acima de $d = 0,5$, o sistema se torna cada vez mais oscilatório, ficando instável quando $d = 2$. Isso ocorre devido o tempo de amostragem do processo ser de meia hora, e a dinâmica da destilação é mais rápida se comparada ao processo de fermentação. Portanto, o tempo de discretização do controlador ficou definido como $d = 0,5h$. A Tabela 9 mostra a configuração escolhida para ambos os processos de destilação. Vale ressaltar que o como o modelo fenomenológico de ambas as destilações são iguais, a configuração escolhida para a destilação 1 se repete para a destilação 2.

Horizonte de predição (N_y)	3
Horizonte de controle (N_u)	2
Intervalo de discretização	0,5h
Penalização pelo erro (α)	1
Penalização pela ação de controle (β)	0,001

Tabela 9: Configuração do controle MPC para ambos os processos de destilação.

Para a definição dos parâmetros do controle PID da destilação, também se utilizou o método do ganho crítico de Ziegler-Nichols, mostrado na seção 5.5. Os valores encontrados dos ganhos do controlador para as duas destilações foram de $K_p = 5$, $K_i = 10$ e $K_d = 0,2$. A Figuras 44 e 45 apresentam uma comparação entre o controle MPC e o PID para o problema servo na a

destilação 1 e 2 respectivamente. As Figuras 46 e 47 apresentam a resposta do processo para o problema regulador, também comparando os dois controladores para a destilação 1 e 2, respectivamente.

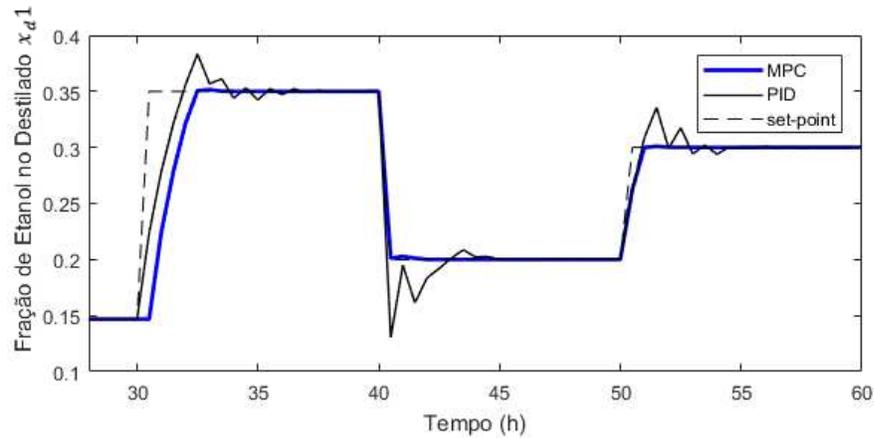


Figura 45: Comparação do controle PID e MPC para o problema servo na destilação 1.

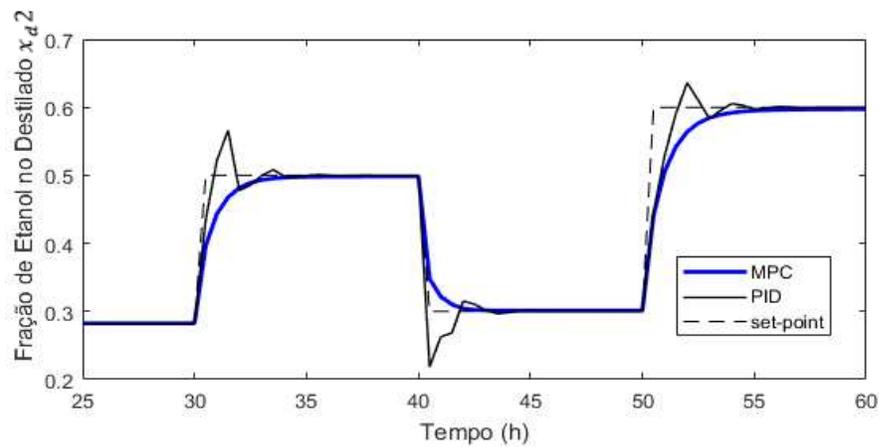


Figura 46: Comparação do controle PID e MPC para o problema servo na destilação 2.

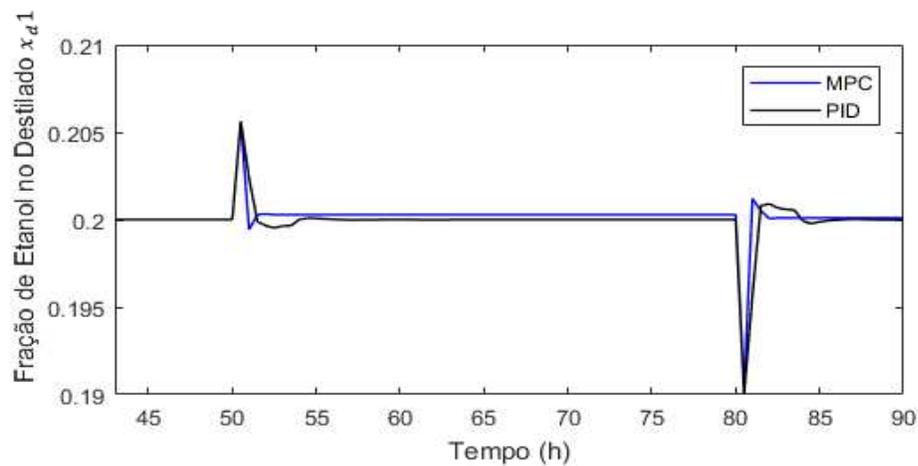


Figura 47: Comparação do controle PID e MPC para o problema regulador na destilação 1.

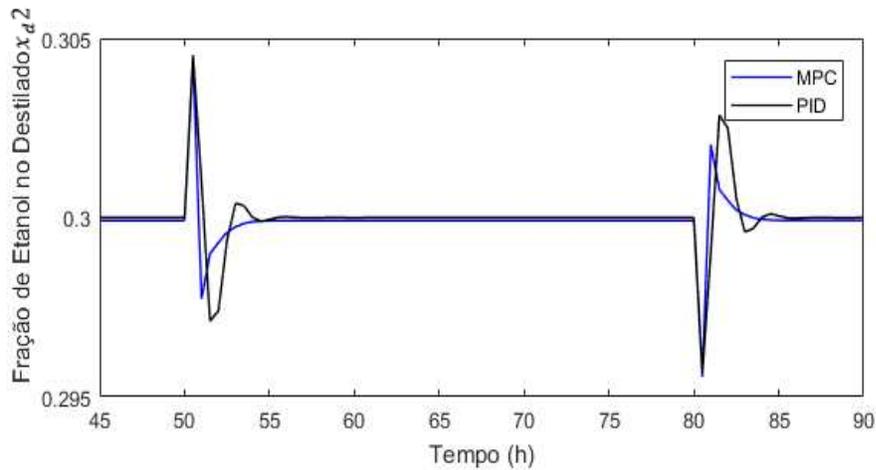


Figura 48: Comparação do controle PID e MPC para o problema regulador na destilação 2.

Para ambos os processos de destilação, o controle MPC apresentou uma melhor performance no problema servo, enquanto o controle PID apresentou um maior tempo de acomodação e um maior sobressinal máximo. Já para o problema regulador, a diferença entre o PID e o MPC não foi tão expressiva, mas ainda assim o controle MPC apresentou melhor performance ao alcançar o estado estacionário mais rapidamente e com menos oscilação no estado transiente.

6.6. Conclusões

Neste capítulo, foi definido o modelo neural dos dois processos de destilação para a implementação do controle preditivo. Implementou-se também uma estratégia de controle PID e comparou com o MPC. Os resultados mostraram que o controle MPC apresentou um melhor desempenho, com um menor sobressinal máximo e um menor tempo de acomodação se comparado com o PID.

Capítulo 7

7. CONTROLE DISTRIBUÍDO PARA A PLANTA

No processo de produção de etanol, as unidades de fermentação e torres de destilação estão diretamente conectadas em série, o que gera um efeito cascata nos processos seguintes pelas mudanças nos processos anteriores. Desta forma, o controle MPC distribuído sequencial foi escolhido para a planta estudada. O DMPC sequencial, proposto neste trabalho, envia a saída predita pelo MPC 1 (Figura 48) de um controlador para o MPC 2 e este por sua vez, para o MPC 3.

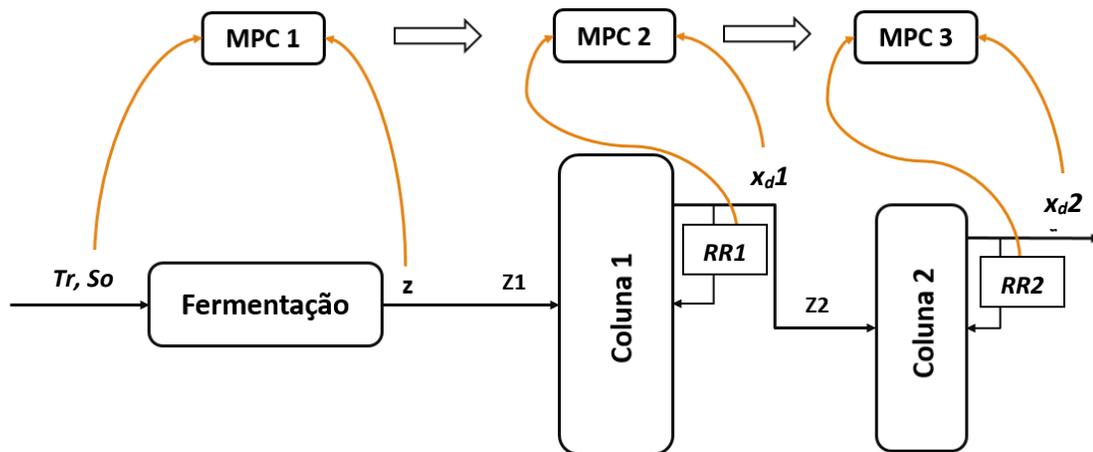


Figura 49: Configuração do controlador DMPC para a planta.

onde S_0 é a concentração de substrato, T_r é a taxa de refluxo e P é a concentração de etanol na saída da fermentação. z_1 e z_2 são as frações de etanol de alimentação, $RR1$ e $RR2$ são as razões de refluxo de cada coluna; x_{d1} e x_{d2} são as frações de etanol de saída em cada uma das colunas de destilação.

7.1. Análise dinâmica da planta de produção de etanol

Para analisar o efeito cascata gerado no processo estudado, considerou-se uma perturbação degrau de +30% na concentração de substrato S_0 e uma perturbação degrau na taxa de reciclo da fermentação T_r . As Figuras 49, 50 e 51 apresentam a resposta à perturbação em S_0 sobre os processos de fermentação, destilação 1 e destilação 2 respectivamente, enquanto as Figuras 52,

53 e 54 apresentam as respostas do sistema à perturbação em T_r para a fermentação, destilação 1 e 2, respectivamente.

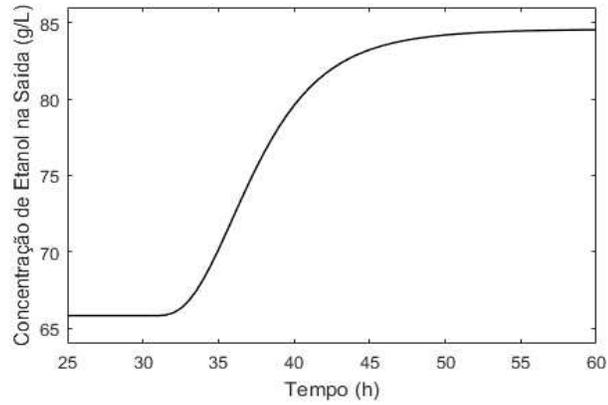


Figura 50: Efeito da perturbação em S_0 sobre a fermentação.

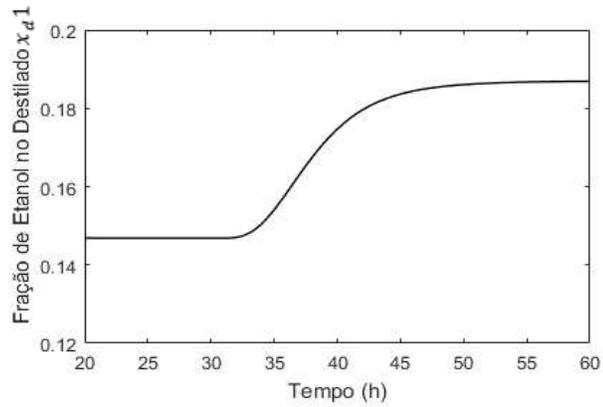


Figura 51: Efeito da perturbação em S_0 sobre a destilação 1.

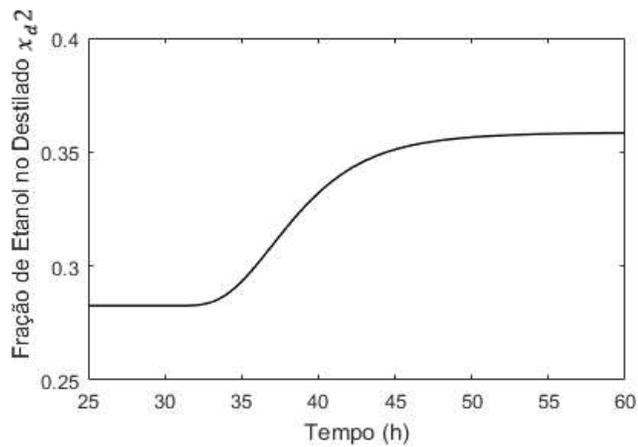


Figura 52: Efeito da perturbação em S_0 sobre a destilação 2.

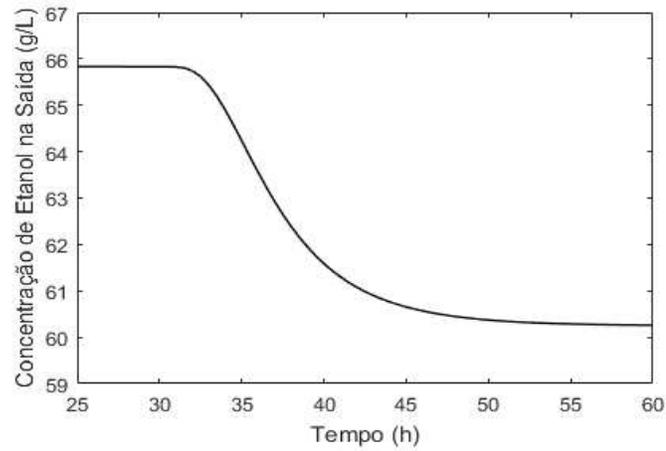


Figura 53: Efeito da perturbação em T_r sobre a fermentação.

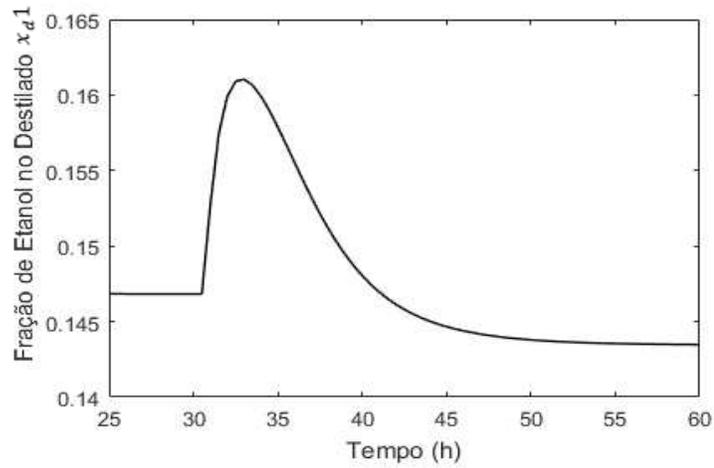


Figura 54: Efeito da perturbação em T_r sobre a destilação 1.

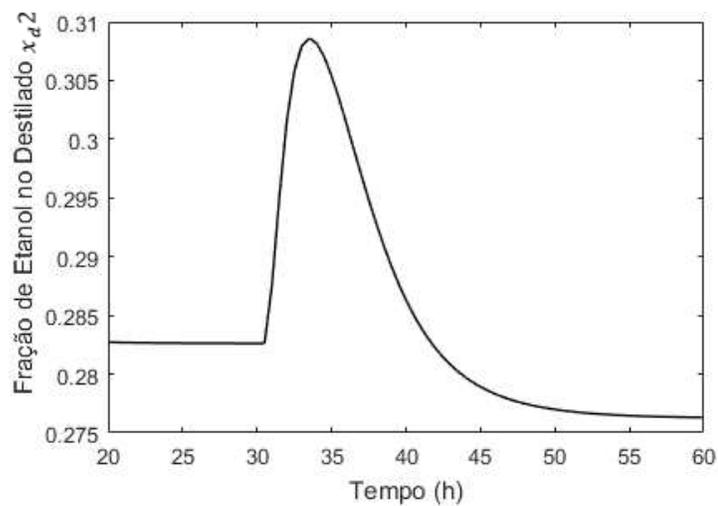


Figura 55: Efeito da perturbação em T_r sobre a destilação 2.

Os resultados acima mostram que as perturbações feitas na entrada da fermentação afetam diretamente as destilações seguinte, o que justifica a implementação de uma estratégia de controle distribuída.

7.2. Aplicação da estratégia de controle distribuído

Como não existe interação retroativa entre os processos da planta estudada, a estratégia de controle implementada ao processo foi o DMPC sequencial, onde a predição do processo anterior é enviada como entrada do processo seguinte. A Figura 55 apresenta o esquema do funcionamento do controle distribuído sequencial para a planta de produção de etanol proposto.

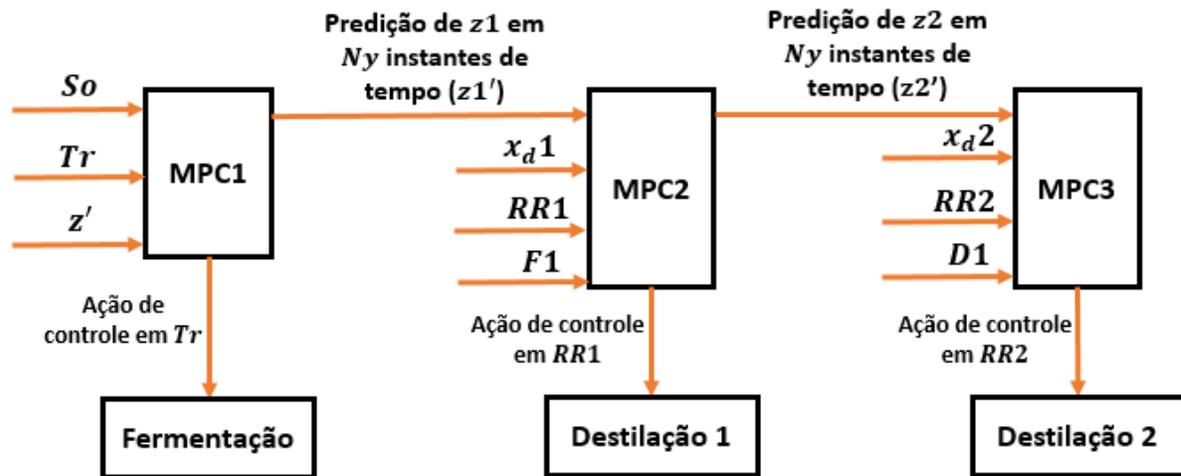


Figura 56: Esquema de funcionamento do controlador DMPC.

O Controle DMPC se inicia com a leitura dos dados de saída da fermentação (z), esses dados são enviados ao MPC 1 e este, por sua vez, gera a ação de controle na variável manipulada T_r e envia a predição de saída z' para o MPC 2, como a saída da fermentação corresponde à entrada da destilação, o MPC 2 utilizará a predição feita pelo MPC 1 para atuar sobre a sua variável manipulada RR_1 . O mesmo ocorre do MPC 2 para o MPC 3, e este processo se repete à cada instante de amostragem do sistema.

Para analisar o efeito do controle DMPC no processo foi feita uma mudança no *set-point* da fermentação de 60 para 70 g/L na variável de saída, de forma a gerar uma ação de controle no MPC 1 e, conseqüentemente, a ação distribuída no MPC 2. A Figura 56 mostra a ação do controlador MPC 1 sobre a fermentação:

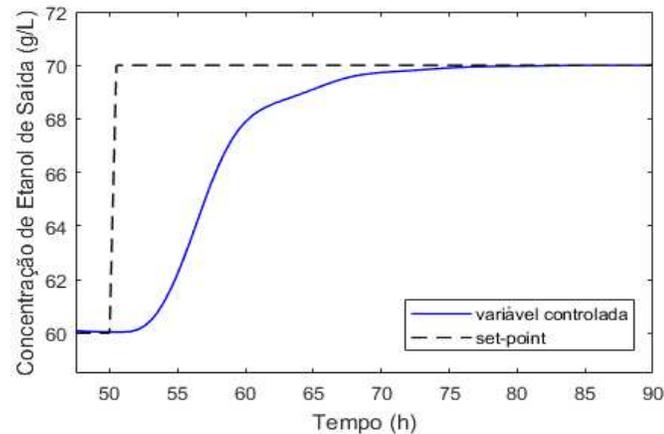


Figura 57: Mudança no set-point da fermentação e atuação do controle MPC

A mudança na concentração de etanol na saída da fermentação afeta diretamente a destilação, gerando um problema regulador para o processo seguinte. O controlador MPC 2 age de forma a manter a saída do processo no *set-point* igual à 0.4. A ação dos controladores PID, MPC e DMPC sobre a primeira destilação são apresentadas na Figura 57.

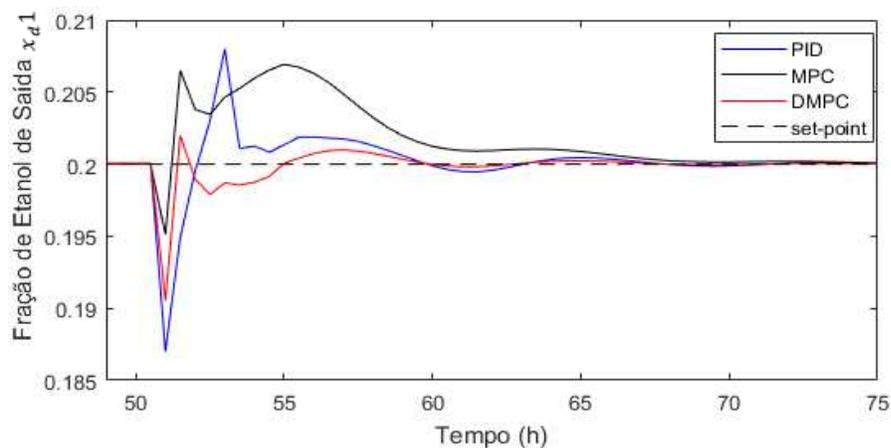


Figura 58: Controle PID, MPC e DMPC para a destilação 1.

O controlador DMPC apresentou uma integral do erro absoluto (IEA) de 0.011, enquanto o mesmo índice para o foi de 0.048 para o PID e 0.062 para o MPC. Além disso, o sobressinal máximo foi de 0.002 para o DMPC, 0.006 para o MPC e 0.007 para o PID. Portanto, o DMPC apresentou melhor desempenho se comparado com o PID e o MPC convencional, tendo uma boa estimativa da interação entre o processo de fermentação e destilação 1. De forma análoga,

foi aplicado uma mudança no *set-point* da saída da destilação 1 (problema servo) deforma a gerar um problema regulador na destilação 2, como mostra a figura 58.

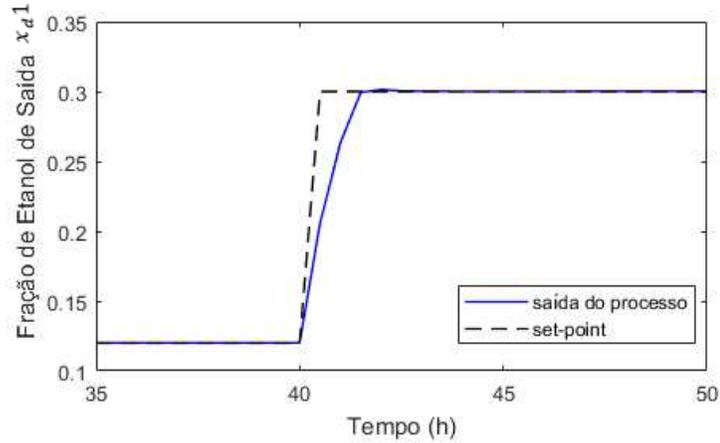


Figura 59: Ação de controle MPC sobre a destilação 1.

A mudança no *set-point* da destilação 1 e a ação de controle do MPC 2 refletem na destilação 2, fazendo com que o MPC 3 utilize as saídas previstas do MPC 2 no controle do processo, este efeito é mostrado na Figura 59 e comparando com os controladores PID e MPC.

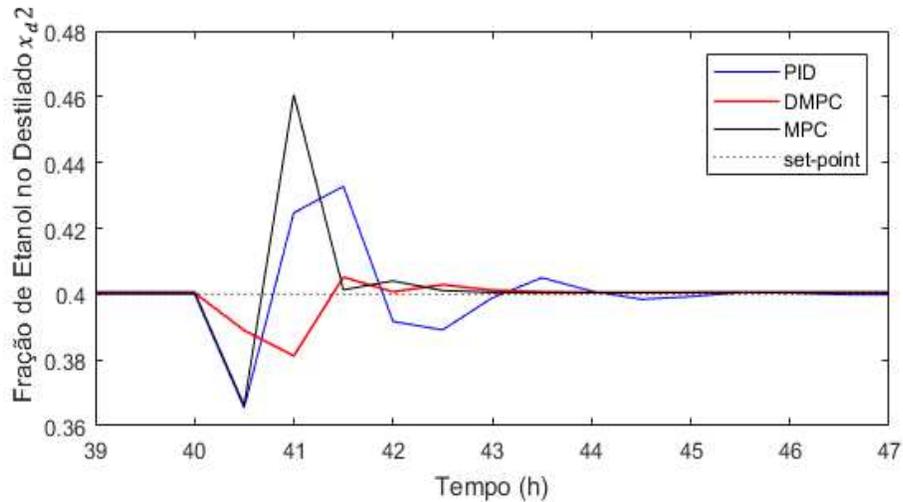


Figura 60: Atuação do controle DMPC na destilação 2.

O controle DMPC apresentou um IEA de 3,5, enquanto o PID e o MPC apresentaram um IEA de 4,1 e 4,2 respectivamente. O sobressinal máximo do controle foi de 0,02 para o DMPC, 0,04 para o MPC e 0,03 para o PID. O tempo de acomodação foi de 3 horas tanto para o MPC, como para o DMPC, enquanto o controle PID teve um tempo de acomodação de aproximadamente

5 horas. Mais uma vez o controle DMPC mostrou um melhor desempenho se comparado com as outras estratégias de controle estudadas.

Para aumentar o grau de perturbação sobre o processo, considerou-se uma mudança no *set-point* na fermentação de 68 para 61 (g/L) no instante de tempo de 50h. Além disso, no mesmo instante de tempo foi efetuada uma mudança no *set-point* da destilação 1 de 0.2 para 0.35. Desta forma, têm-se uma soma dos efeitos oriundas destas mudanças. A Figura 60 apresenta o comportamento da fermentação em relação à mudança no *set-point*, enquanto a Figura 61 apresenta a resposta dinâmica da destilação 1 para um problema regulador dos controladores PID, MPC e DMPC.

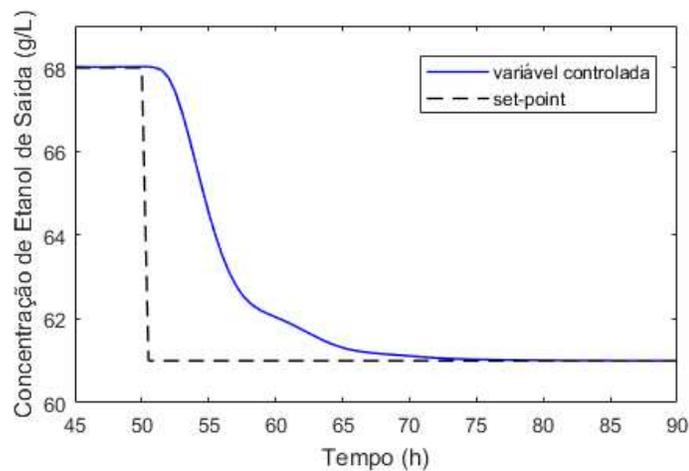


Figura 61: Mudança no set-point da fermentação e ação do controle MPC.

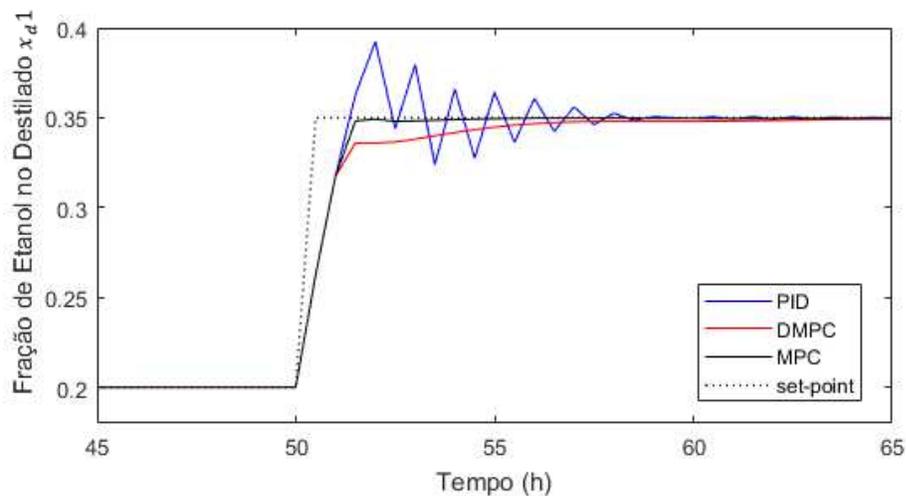


Figura 62: Problema servo da destilação 1 para os controles PID, MPC e DMPC somado ao efeito da mudança na fermentação.

O controle DMPC apresentou um IEA de 3.3, enquanto os controladores MPC e PID apresentaram um IEA de 2.1 e 4, respectivamente. Além disso, o tempo de acomodação foi de 1h para o MPC, 7h para o DMPC e 9h para o PID. Portanto, o DMPC apresentou um desempenho inferior ao do MPC quando se trata de mudanças sobrepostas na entrada dos processos. Isso ocorre devido o DMPC gerar uma ação de controle desnecessária, oriunda da informação da dinâmica do processo anterior. A diferença nas ações de controle é mostrada na Figura 63.

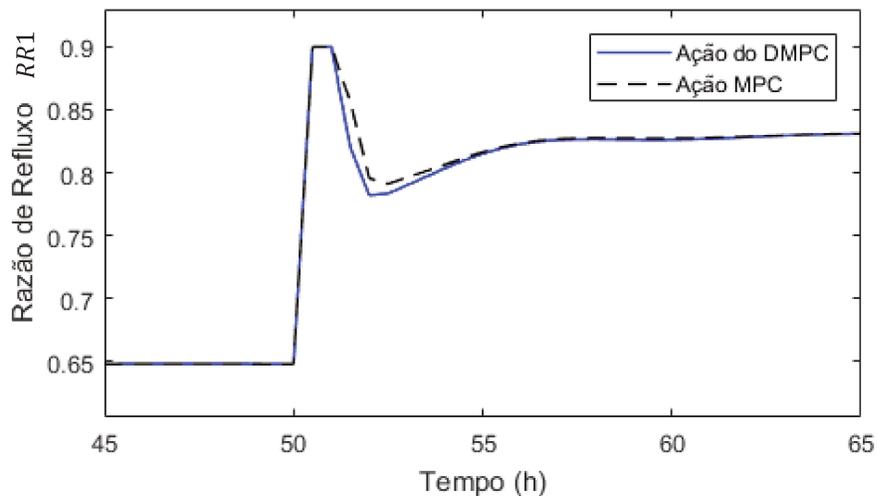


Figura 63: Comparação entre as ações de controle MPC e DMPC.

Portanto, os resultados mostram que, para problemas de controle “regulador”, o controle DMPC se adequou bem o processo estudado, considerando as variações nos processos anteriores. Seu tempo de acomodação aumentou quando foi imposto o problema servo no processo anterior no mesmo instante de tempo, apresentando uma perda de performance para essas condições. Entretanto, mesmo nessas condições o controle apresentou melhores resultados que o controlador PID

Capítulo 8

8. CONCLUSÕES E SUGETÕES DE TABALHOS FUTUROS

8.1. Conclusão

Apesar de os processos de fermentação e destilação apresentarem uma dificuldade para implementação de um controle eficiente, os resultados apresentados mostram que, tanto o controle MPC como o DMPC foram eficazes no controle da planta de produção de etanol.

Com o modelo fenomenológico da planta, representando um processo real, foi possível obter modelos neurais com bons ajustes às dinâmicas dos processos estudados. Estes modelos foram utilizados para a implementação dos controles preditivos. Mesmo com intervalos de discretização elevados, como 5 horas, o controlador conseguiu manter o controle de ambos os processos. Quando comparados com o controlador PID, o controle MPC e DMPC foram superiores tanto no tempo de acomodação, como na oscilação da resposta e nas mudanças da variável manipulada.

O controle DMPC apresentou melhor desempenho no transiente de ambos os processos em relação ao MPC convencional e ao PID. Quando se aplicou mudanças no *set-point* nos processos no mesmo instante de tempo, o DMPC apresentou uma pequena perda de performance. Mesmo assim, o DMPC se mostrou uma estratégia eficiente no controle do processo de destilação e fermentação por considerar a interação entre as operações.

8.2. Sugestões de trabalhos futuros

- Estudar o controle preditivo distribuído para uma planta industrial de produção de etanol anidro, adicionando outras colunas de destilação e o processo de desidratação para obtenção do etanol de alta pureza.
- Estudar o comportamento do controlador para valores diferentes de tempo de amostragem dos sensores, que neste trabalho foi estabelecido de 30 minutos tanto para a fermentação como a destilação.

- Estudar o comportamento do controlador MPC centralizado com múltiplas entradas e saídas (MIMO) para o processo estudado e compará-lo com o controle distribuído.
- Estudar diferentes abordagens do controle distribuído, alterando o nível de comunicação e influência um processo sobre o outro.
- Implementar incertezas e/ou ruídos das medições de forma a desenvolver uma estratégia de controle distribuído robusto e resistente a falhas.
- Incrementar o modelo de destilação, desenvolvendo um projeto para as colunas de destilação de acordo com as correntes do processo de produção de etanol e considerar correlações de ELV para misturas reais.

9. REFERÊNCIAS

- AGATONOVIC-KUSTRIN, S.; BERESFORD, R. Basic concepts of artificial neural network (ANN) modeling and its application in pharmaceutical research. **Journal of Pharmaceutical and Biomedical Analysis**, v. 22, n. 5, p. 717–727, 2000.
- ANDRIETTA, S.R. Modelagem, simulação e controle de fermentação alcoólica contínua em escala industrial. In: Galindo, E., Ramírez, O. (Eds.), *Advances in Bioprocess Engineering*. Springer Netherlands, pp. 47–52, 1994.
- ANG, K. H. et al. PID Control System Analysis , Design , and Technology. **IEEE transactions on control systems**, v. 13, n. 4, p. 559–576, 2005.
- BRETHAUER, S.; WYMAN, C. E. Bioresource Technology Review : Continuous hydrolysis and fermentation for cellulosic ethanol production. **Bioresource Technology**, v. 101, n. 13, p. 4862–4874, 2010.
- BUCKERIDGE, M. S.; DANTAS, W. Routes for cellulosic ethanol in brazil. **IEEE Transactions on Control Systems Technology**, v. 1, 2014.
- CAMPONOGARA, E. et al. Distributed model predictive control. **IEEE Control Systems Magazine**, v. 22, n. 1, p. 44–52, 2002.
- CARLOS, E. G. A. R. A.; PRETI, M.; MORARI, M. Model Predictive Control : Theory and Practice a Survey. **Automatica**, v. 25, n. 3, 1989.
- CHATTAWAY, T.; GOMA, G.; RENAUD, P. Modelling Ethanol and Secondary Inhibitions of Ethanol Fermentation in a Multistage Reactor. **Biotechnology and Bioengineering**, v. 32, p. 271–276, 1988.
- CHRISTOFIDES, P. D.; SCATTOLINI, R.; MU, D. Distributed model predictive control : A tutorial review and future research directions. **Computers and Chemical Engineering**, v. 51, p. 21–41, 2013.
- DAHOU, B. et al. Modelling and adaptive predictive control of a continuous fermentation process. v. 16, n. March, 1992.
- DAOUTIDIS, P.; TANG, W.; JOGWAR, S. S. Decomposing complex plants for distributed control: Perspectives from network theory. **Computers and Chemical Engineering**, 2017.
- DIAS, M. O. S. et al. Evaluation of process configurations for second generation integrated with first generation bioethanol production from sugarcane. **Fuel Processing Technology**, v. 109, p. 84–89, 2013.
- GUPTA, N. Artificial Neural Network. **Network and Complex Systems**, v. 3, n. 1, p. 24–28, 2013.

- HERRERA, W. E. et al. Modeling And Control of a Continuous Ethanol Fermentation Using a Mixture of Enzymatic Hydrolysate and Molasses from Sugarcane. **Chem. Eng. Trans.** v. 50, p. 169–174, 2016.
- HOCALAR, A.; T??RKER, M. Model based control of minimal overflow metabolite in technical scale fed-batch yeast fermentation. **Biochemical Engineering Journal**, v. 51, n. 1–2, p. 64–71, 2010.
- HOSKINS, J. C.; HIMMELBLAU, D. M. Artificial neural network models of knowledge representation in chemical engineering. **Computers & Chemical Engineering**, v. 12, n. 9–10, p. 881–890, 1988.
- JORGENSEN, J. B.; PETERSEN, L. N.; RAWLINGS, J. B. Economic Optimization of Spray Dryer Operation using Nonlinear Model Predictive Control with State Estimation. **IFAC Proceedings Volumes (IFAC-PapersOnline)**, v. 48, p. 507–513, 2015.
- KELLER, R.; DUNN, I. J. Computer Simulation of the Biomass Production Rate. **Journal of Chemical Technology and Biotechnology**, p. 784–790, 1978.
- LAO, L.; ELLIS, M.; CHRISTOFIDES, P. D. Economic model predictive control of transport-reaction processes. **Industrial and Engineering Chemistry Research**, v. 53, n. 18, p. 7382–7396, 2014.
- LUONG, J. H. T. Kinetics of ethanol inhibition in alcohol fermentation. **Biotechnology and bioengineering**, v. 27, n. 3, p. 280–285, 1985.
- MELEIRO, L.A; FILHO, R. M. A Projeto e aplicação de controladores baseados em modelos lineares, neurais e nebulosos. Campinas: Faculdade de Engenharia Química, Universidade Estadual de Campinas, 2002. Tese (Doutorado).
- MELEIRO, L. A. .; FILHO, R. M. A self-tuning adaptive control applied to an industrial large scale ethanol production. **Computers & Chemical Engineering**, v. 24, n. 2–7, p. 925–930, 2000.
- MELEIRO, L. A. DA C.; VON ZUBEN, F. J.; FILHO, R. M. Constructive learning neural network applied to identification and control of a fuel-ethanol fermentation process. **Engineering Applications of Artificial Intelligence**, v. 22, n. 2, p. 201–215, 2009.
- MISHRA, P.; KUMAR, V.; RANA, K. P. S. A fractional order fuzzy PID controller for binary distillation column control. **Expert Systems With Applications**, v. 42, n. 22, p. 8533–8549, 2015.
- MOROSAN, P. D. et al. Building temperature regulation using a distributed model predictive control. **Energy and Buildings**, v. 42, n. 9, p. 1445–1452, 2010.
- MULIA-SOTO, J. F.; FLORES-TLACUAHUAC, A. Modeling , simulation and control of an internally heat integrated pressure-swing distillation process for bioethanol separation. **Computers and Chemical Engineering**, v. 35, n. 8, p. 1532–1546, 2011.

PAYA, B. A.; ESAT, I. I.; BADI, M. N. M. Artificial neural network based fault diagnostics of rotating machinery using wavelet transforms as a preprocessor. **Mechanical systems and signal processing**, v. 11, n. 5, p. 751–765, 1997.

QIN, S. J.; BADGWELL, T. A. An overview of industrial model predictive control technology. **Control Engineering Practice**, v. 11, n. 7, p. 733–764, 2003.

RAZBANI, O.; ASSADI, M. Artificial neural network model of a short stack solid oxide fuel cell based on experimental data. **Journal of Power Sources**, v. 246, p. 581–586, 2014.

ROCHA, Rosiane Ribeiro. Controle preditivo distribuído de processos lineares. 2014. 185 f. Dissertação (Mestrado em Engenharias) - Universidade Federal de Uberlândia, Uberlândia, 2014.

ROCHA, R. R.; OLIVEIRA-LOPES, L. C.; CHRISTOFIDES, P. D. Chemical Engineering Research and Design Partitioning for distributed model predictive control of nonlinear processes. **Chemical Engineering Research and Design**, v. 139, p. 116–135, 2018.

SARLE, W. S. Neural Networks and Statistical Models. **Proceedings of the Nineteenth Annual SAS Users Group International Conference, April, 1994**, p. 1–13, 1994.

SHEMYAKINA, T. A.; TARKHOV, D. A.; B, A. N. V. Neural Network Technique for Processes Modeling in Porous Catalyst and Chemical Reactor. **Advances in Neural Networks** p. 547–554, 2016.

SODRE, C. H.; WILSON, J. A.; JONES, W. Practical evaluation of hold-up for passive decoupling in distillation column. **Braz. J. Chem. Eng.**, São Paulo , v. 17, n. 4-7, p. 1003-1014, Dec. 2000.

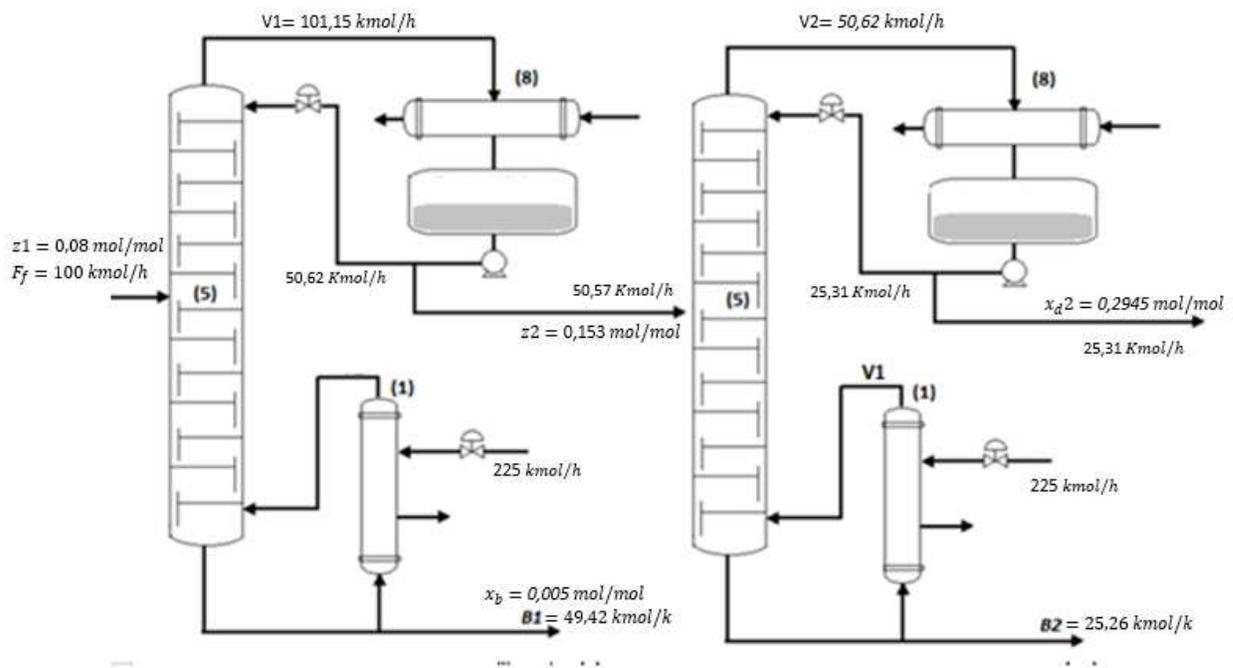
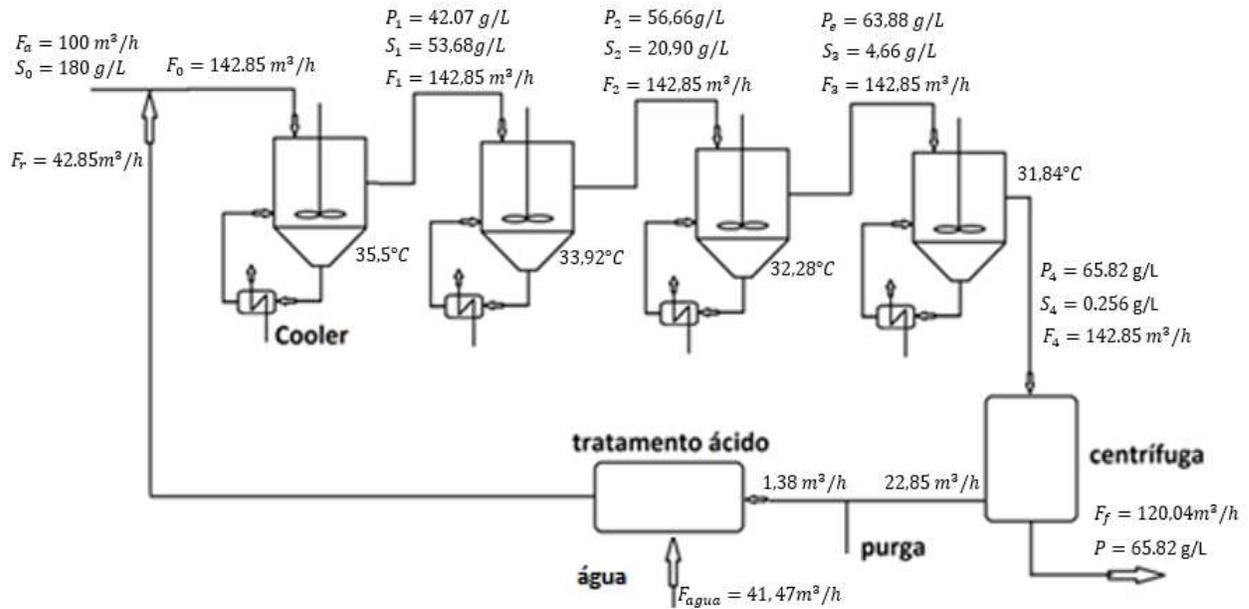
SOUZA, A. P. DE et al. Sugarcane as a Bioenergy Source: History , Performance , and Perspectives for Second-Generation Bioethanol. **BioEnergy Research** p. 24–35, 2014.

VENKAT, A. N.; RAWLINGS, J. B.; WRIGHT, S. J. Stability and optimality of distributed model predictive control. **Proceedings of the 44th IEEE Conference on Decision and Control**, p. 6680–6685, 2005.

YAMAKAWA, C. K. et al. Study of influence of yeast cells treatment on sugarcane ethanol fermentation: Operating conditions and kinetics. **Biochemical Engineering Journal**, v. 147, n. March, p. 1–10, 2019.

APÊNDICE A

Variáveis do processo no estado estacionário



ANEXO 1

Código do processo em Matlab

PROGRAMA PRINCIPAL

```

ts = 150; %tempo de simulação
z1 = 0.065
Fdest1 = 100;
Fdest2 = 50;
z2 = 0.13
cont6 = 0;
cont7 = 0;
%-----Parâmetros da fermentação-----
global Fa; global P4; global Fj1; global Fj2; global Fj3; global Fj4;
global To; global Tje; global So; global y_Ny_dest1
global LMDT_1; global LMDT_2; global LMDT_3; global LMDT_4;
global V1 V2 V3 V4; global FaV_1; global N; global net_ferm; global Ny_ferm;
global Nu_ferm; global set_ferm; global z1; global Vx1_8;
global S4; global PS; global PSo; global tx_r; global Ptx; global P4v
global PP4; global int; global Px1; global Pz1; global PRR2; global z2
global PR2; global Pz2; global Px2; global PF2; global Fdest2; global PD1
global Vx2_8; global R1; global PRR1; global net_dest1; global net_dest2
global vaz_D2; global vaz_D1; global set_dest2; global Nu_dest2; global
Ny_dest2
global PR; global Px; global x8; global net_dest; global FVT;
global Pz; global PF; global Nu_dest; global p_feed; global Pfv
global Ny_dest; global set_dest; global n_estagios; global y_Ny_ferm

fa_max = 150;
fa_min = 40;
incr_Fa = 0;
incr_So = 0;
incr_tx_r = 0;
s0_max = 190;
s0_min = 170;
incr_s0 = 0;
Tsim = 200;
tmc = 0.01;
tx_r = 0.3; %Taxa de reciclo
So = 180; %s0_min;
Sol = So;
Fao = 100;
Fa = Fao;
Y1c=[]; Y2c=[]; Y3c=[]; Y4c=[]; FaV = [];
Y5c=[]; Y6c=[]; Y7c=[]; Y8c=[]; SoV = [];
Y9c=[]; Y10c=[]; Y11c=[]; Y12c=[]; tx_rV = [];
Y13c=[]; Y14c=[]; Y15c=[]; Y16c=[]; P4v = [];
Y17c=[]; Y18c=[]; Y19c=[]; Y20c=[]; S4v = [];
Y21c=[]; Y22c=[]; Y23c=[]; Y24c=[]; X4v = [];
time=[]; tf=0; tk=0; D8 = []; Nv = [];
VD1 = [];
VR1 = []; VRR1 = [];
VF1 = [];
Vz1 = [];

```

```

Vx1 = [];
temperatura_col_1 = [];
vapor = [];
x8 = [];
VD2 = [];
VR2 = [];    VRR2 = [];
VF2 = [];
Vz2 = [];
Vx2 = [];
temperatura_col_2 = [];
Vtempo = [];

Vx1_8 = [];
Vx2_8 = [];

Xp = [];
timee = [];
un = [];
xn_1 = [];
xn_1 = [];
xn_2 = [];
zn = [];
conta = 0
LMDT_1 = 3.2865; LMDT_2 = 3.3467; LMDT_3 = 3.3924; LMDT_4 = 3.8677;

Fj1 = 400; Fj2 = 350; Fj3 = 180; Fj4 = 60;
To = 28; Tje = 28;
% condições iniciais para as equações diferenciais
% (estado estacionário de referência)
S1 = 53.68781098062961; S2 = 20.90738239240737;
S3 = 4.66720395549191; S4 = 0.76001783945483;
X1 = 29.39006452236358; X2 = 30.47181992376290; %celulas (g/L)
X3 = 31.00775236105115; X4 = 31.13669761797306; %etanol (g/L)
P1 = 42.07362937154644; P2 = 56.66091967945654;
P3 = 63.88779815113933; P4 = 65.62649508306343;
T1 = 33.54060742042542; T2 = 33.51925388973194;
T3 = 33.49545662842527; T4 = 33.45838096389363;
Tj1 = 30.19592663145976; Tj2 = 30.11653037114717;
Tj3 = 30.04887447548435; Tj4 = 29.54975672878527;
Tc1 = 31.22910715484541; Tc2 = 31.29132717609687;
Tc3 = 31.33874696193899; Tc4 = 31.82706300658850;

x0 = [S1 S2 S3 S4 P1 P2 P3 P4 X1 X2 X3 X4 T1 T2 T3 T4 Tc1 Tc2 Tc3 Tc4 Tj1 Tj2
Tj3 Tj4]';

tic
cont = 0;
cont2 = 0;
cont3 = 0;

%-----Parâmetros da DESTILAÇÃO 1-----
for i = 1:1:100
    set(i) = 60;
end
for i = 101:1:220
    set(i) = 70;

```

```

end
%limpando os vetores de armazenamento
VD = [];
VR = [];
VF = [];
Vz = [];
Vx = [];
Vtempo = [];
temperatura = [];
vapor = [];

base = 'C2:C7';
topo = 'E2:E7';
W = xlsread('dados termodinamicos.xlsx',topo);
Z = xlsread('dados termodinamicos.xlsx',base);

n_estagios = 8; %numero de estagios da coluna 1
p_feed = 5; %estágio de alimentação da coluna 1

x1(8) = 0.98;
x1(7) = 0.96;
x1(6) = 0.88;
x1(5) = 0.74;
x1(4) = 0.66;
x1(3) = 0.45;
x1(2) = 0.22;
x1(1) = 0.13; %número de estágios na coluna 1, chutes iniciais de 0.5

R1 = 50;
RR1 = 0.5; %vazão de refluxo inicial
vaz_D1 = 50;
V_1 = 100;
V̄V1 = calibracao_reboiler_invert_dest(x1, V_1, W, Z); %vazão de alimentação
no reboiler %240.17

for i = 2:7
    Mol(i) = 5;
%valor do numero de mols contidos nos pratos citados em "i"
end

p = 100; % kPa, constante ao longo da coluna
%chute das temperaturas iniciais

for i = 1:8
t1(i) = 350; % K
end

%numero de mols em excesso

M1(1) = 10;
M1(8) = 15;
for i = 2:5
    M1(i) = 20;
end

```

```

for i = 6:7
    M1(i) = 10;
end

%Leitura dos dados termodinamicos
%base
a2 = Z(1);
b2 = Z(2);
c2 = Z(3);
%topo
a1 = W(1);
b1 = W(2);
c1 = W(3);

%-----Parâmetros da DESTILAÇÃO 2-----
x2(8) = 0.98;
x2(7) = 0.96;
x2(6) = 0.88;
x2(5) = 0.74;
x2(4) = 0.66;
x2(3) = 0.45;
x2(2) = 0.22;
x2(1) = 0.13; %número de estágios na coluna 2, chutes iniciais

R2 = 30;
RR2 = 0.5; %vazão de refluxo inicial
B2 = 25;
V_2 = 50;
VV2 = calibracao_reboiler_invert_dest(x2, V_2, W, Z); %vazão de alimentação
no reboiler

for i = 2:7
    Mo2(i) = 2.5;
%valor do numero de mols contidos nos pratos citados em "i"
end

p = 100; % kPa, constante ao longo da coluna
%chute das temperaturas iniciais
for i = 1:8
    t2(i) = 350; % K
end

%numero de mols em excesso

M2(1) = 5;
M2(8) = 5;
for i = 2:5
    M2(i) = 10;
end
for i = 6:7
    M2(i) = 5;
end

%valores iniciais para o processo iterativo
fator2 = 1;

```

```

cont = 0; %contador da perturbação randômica
cont1 = 0;
cont2 = 0;
cont3 = 0;
cont4 = 0;
cont5 = 0;
cont8 = 0;
cont9 = 0;
cont10 = 0;
conta_dest1 = 0; %contador do intervalo de atuação do MPC
conta_dest2 = 0;
tempo = 0;
int = 0;
comp = zeros(1,8); %vetor para o armazenamento das composições
V_1 = zeros(1,8); %vetor para o armazenamento das vazões de vapor
V_2 = zeros(1,8);
fat = 0;%fator de integração para o controlador pi.
%!!!!!!!!!!!!!!!!!!!!!!!!!!!!!!!!!!!!!!!!!!!!!!!!!!!!!!!!!!!!!!!!!!!!!!!!!!!!!!
%
%                               ENTRADA DO LOOP
tmc = 0.5;
passo = tmc;
cont_ferm = 0; %instaciador do controlador da fermentação
int = 1; %contador de iterações
while tempo < ts %entrada no
laço do novo valor de x

% %-----FERMENTAÇÃO-----
% tempo de integração e condição inicial
tk=tf+tk; %variável auxiliar para o cálculo do vetor tempo tkk
t0 = 0;
passo_ferm = 0.01; %0.1;
tf = tmc; %0.05;
tspan = [t0:passo_ferm:tf];

%Resolução do modelo dinâmico
[T,Y] = ode45('ODE_ferm',tspan,x0);
Siz=size(T);
tkk = tk*ones(Siz(1),1) + T; %vetor tempo corrigido

%Atualização do vetor de estado inicial
x0=Y(Siz(1),:);
%geração do vetor Fa a cada 0.5 h
Fav = Fa*ones(Siz(1),1);
Sov = So*ones(Siz(1),1);
tx_rv = tx_r*ones(Siz(1),1);
Fo = Fa/(1 - tx_r);
FR = Fo - Fa;
XR = 90; %Concentração células do reciclo
XL = 180; %Concentração de células no creme de levedura, depois da
centrifuga
XVT = 3;
FL1 = FR*XR/XL;
F1 = Fo; F2 = Fo; F3 = Fo; F4 = Fo;
%V1 = 210.374; V2 = 268.037; V3 = 316.663; V4 = 208.208;
[n_Y_LINHA n_Y_COLUNA] = size(Y);

```



```

        % Ajuste dos vetores com a trajetória no tempo dos 24 estados
        Y1=Y(:,1); Y5=Y(:,5); Y9=Y(:,9); Y13=Y(:,13); Y17=Y(:,17);
Y21=Y(:,21);
        Y2=Y(:,2); Y6=Y(:,6); Y10=Y(:,10); Y14=Y(:,14); Y18=Y(:,18);
Y22=Y(:,22);
        Y3=Y(:,3); Y7=Y(:,7); Y11=Y(:,11); Y15=Y(:,15); Y19=Y(:,19);
Y23=Y(:,23);
        Y4=Y(:,4); Y8=Y(:,8); Y12=Y(:,12); Y16=Y(:,16); Y20=Y(:,20);
Y24=Y(:,24);

        Y1c=[Y1c;Y1]; Y2c=[Y2c;Y2]; Y3c=[Y3c;Y3]; Y4c=[Y4c;Y4];
        Y5c=[Y5c;Y5]; Y6c=[Y6c;Y6]; Y7c=[Y7c;Y7]; Y8c=[Y8c;Y8];
        Y9c=[Y9c;Y9]; Y10c=[Y10c;Y10]; Y11c=[Y11c;Y11]; Y12c=[Y12c;Y12];
        Y13c=[Y13c;Y13]; Y14c=[Y14c;Y14]; Y15c=[Y15c;Y15]; Y16c=[Y16c;Y16];
        Y17c=[Y17c;Y17]; Y18c=[Y18c;Y18]; Y19c=[Y19c;Y19]; Y20c=[Y20c;Y20];
        Y21c=[Y21c;Y21]; Y22c=[Y22c;Y22]; Y23c=[Y23c;Y23]; Y24c=[Y24c;Y24];
        time=[time;tkk];
        % discretização a cada 30 min de simulação
        FaV = [FaV;Fa]; SoV = [SoV;So]; tx_rV = [tx_rV;tx_r];
        P4 = Y(51,8); P4v = [P4v;P4];
        S4 = Y(51,3); S4v = [S4v;S4];
        X4 = Y(51,12); X4v = [X4v;X4];
        VFVT(int) = FVT;

%         FaV_1 = FaV';
%         S4v_1 = S4v';
        % contador no numero de pontos
        n = size(FaV);
        N = n(1);
        Nv = [Nv;N];
%CONTROLE FERMENTAÇÃO

        if tempo == 5
            set_ferm = 68;
        end
        if tempo == 50
            set_ferm = 61;
        end
        if tempo == 100
            set_ferm = 65;
        end
        % controle preditivo para a fermentação
        if tempo >= 20
            if cont_ferm == 1 %frequência de atuação do controlador
                cont_ferm = 0;
                Nu_ferm = 1;
                Ny_ferm = 20;
                uo = ones(1,Nu_ferm).*tx_r; %integral (u)
%                uo = zeros(1,Nu_ferm);%diferencial (u_diff)
                lb = 0.1;
                ub = 0.6;
                u =
fmincon('otimizador_ferm',uo,[],[],[],[],ones(1,Nu_ferm)*lb,ones(1,Nu_ferm)*u
b);
                tx_r = u(1);
            end

```

```

        cont_ferm = cont_ferm + 1;
    end
%controle PID fermentação

    %kc=0.0029
    %Pc = 26
% if tempo >=5
% e1 = P4v(int) - set_ferm;          % e(k)
% e2 = P4v(int-1) - set_ferm;      % e(k-1)
% e3 = P4v(int-2) - set_ferm;
% eint = sum((P4v(int-10:int) - set_ferm)*0.5);
%
% Kp = 0.0012;
% Ki = 20;
% Kd = 1;
% tx_r_corr = Kp*((e1) + 1/Ki*(eint) + ((Kd)*(e1-e2)/0.5));
% tx_r = tx_r + tx_r_corr;
% end
%     if tx_r > 0.6
%         tx_r = 0.6;
%     elseif tx_r < 0.1
%         tx_r = 0.1;
%     end
%-----FIM DA FERMENTAÇÃO-----

%
%-----DESTILAÇÃO 1-----
integral = 0;
while integral<50

for i = 2:7
    L1(i) = (M1(i) - Mo1(i))/0.1;          %0.1 é a constante hidráulica
end
%Cálculo bolha P(x,y,T)
fator = 1;
Fdest1 = FVT;
z1 = P4/1000;    %torna a saída da fermentação igual à entrada da destilação
1

% if tempo < 30
% z1 = 0.062;
% end
% if tempo == 30
% z1 = 0.072;
% end

while abs(fator) > 0.001
    p1sat = exp(a1 - (b1./(c1+t1)));
    p2sat = exp(a2 - (b2./(c2+t1)));
    pcalc = p1sat.*x1 + p2sat.*(1-x1);
    ft = pcalc - p;
    if sum(abs(ft)) > 0.001
        dt = x1.*p1sat.*b1*2./(t1+c1) + (1-x1).*p2sat.*b2*2./(t1+c2);
%derivada de "pcalc"
        t1 = t1 - ft./dt;
%calcula um novo valor para "t"
    end
end

```

```

        fator = ft/dt;
%fator de convergência do laço
    end
end
y1 = (x1.*p1sat)./pcalc;
%fração de vapor de metanol em cada estágio(y1)

%Calibração experimental para o reboiler
V_1(1) = calibracao_reboiler_dest(x1, VV1, W, Z);

%Balanço de energia na alimentação
QF = balanco_energia_alimentacao_dest(x1, t1, W, Z);
V_1(5) = V_1(1) - Fdest1*QF;

%Balanço de energia no prato de topo
Qtopo = balanco_energia_topo_dest(x1, t1, W, Z);
V_1(7) = V_1(5) - R1*(Qtopo);
R1 = RR1*V_1(7);
vaz_D1 = V_1(7) - R1;
B1 = L1(2) - V_1(1);
%Cálculo das equações diferenciais
[dM1,dX1] = calculo_diferenciais_dest(V_1, R1, vaz_D1, B1, Fdest1, L1, M1,
x1, y1, z1);

passo = 0.01;
xlnovo = x1 + dX1.*(passo);
Mlnovo = M1 + dM1.*(passo);
x1 = xlnovo;
M1 = Mlnovo;

integral = integral+1;
end

% Perturbações randômicas
% if tempo >= 30
%     RR1 = 0.55;
% end

% % if tempo == 20
% %     VV1 = VV1 - VV1*0.1;
% % end

    incr_RR1 = 0;
    incr_F1 = 0;
    incr_z1 = 0;
    if tempo >= 1
        if cont8 == 10/tmc
            incr_RR1 = RR1*(-0.3 + (0.6)*rand);
            cont8 = 0;
        end
        if cont9 == 20/tmc
            incr_F1 = Fdest1*(-0.3 + (0.6)*rand);
            cont9 = 0;
        end
        if cont10 == 40/tmc
            incr_z1 = z1*(-0.1 + (0.2)*rand);
            cont10 = 0;
        end
    end

```

```

        end
        cont8 = cont5+1;
        cont9 = cont6+1;
        cont10 = cont7+1;
    end
    RR1 = RR1 + incr_RR1;
    Fdest1 = Fdest1 + incr_F1;
    z1 = z1 + incr_z1;
    % restrição das pretubações
    if RR1 > 0.9
        RR1 = 0.5;
    elseif RR1 < 0.1
        RR1 = 0.5;
    end
    if Fdest1 > 170
        Fdest1 = 130;
    elseif Fdest1 < 100
        Fdest1 = 130;
    end
    if z1 > 0.075
        z1 = 0.065;
    elseif z1 < 0.05
        z1 = 0.065;
    end
    end

%-----DESTILAÇÃO 2-----
integra2 = 0;
while integra2<50 %faz a integração até 0.5 num passo de 0.01 para igualar
com a da fermentação
for i = 2:7
    L2(i) = (M2(i) - Mo2(i))/0.1;          %0.1 é a constante hidráulica
end
%Cálculo bolha P(x,y,T)
fator = 1;
Fdest2 = vaz_D1;
z2 = x1(8);          %torna a saída da fermentação igual à entrada da destilação
while abs(fator) > 0.001
    p1sat = exp(a1 - (b1./(c1+t2)));
    p2sat = exp(a2 - (b2./(c2+t2)));
    pcalc = p1sat.*x2 + p2sat.*(1-x2);
    ft = pcalc - p;
    if sum(abs(ft)) > 0.001
        dt = x2.*p1sat.*b1*2./(t2+c1) + (1-x2).*p2sat.*b2*2./(t2+c2);
    %derivada de "pcalc"
        t2 = t2 - ft./dt;
    %calcula um novo valor para "t"
        fator = ft/dt;
    %fator de convergência do laço
    end
end
y2 = (x2.*p1sat)./pcalc;
%fração de vapor de metanol em cada estágio(y1)

%Calibração experimental para o reboiler
V_2(1) = calibracao_reboiler_dest(x2, VV2, W, Z);

```

```

%Balanço de energia na alimentação
QF = balanco_energia_alimentacao_dest(x2, t2, W, Z);
V_2(5) = V_2(1) - Fdest2*QF;

%Balanço de energia no prato de topo
Qtopo = balanco_energia_topo_dest(x2, t2, W, Z);
V_2(7) = V_2(5) - R2*(Qtopo);
R2 = RR2*V_2(7);
vaz_D2 = V_2(7) - R2;
B2 = L2(2) - V_2(1);

%Cálculo das equações diferenciais
[dM2,dX2] = calculo_diferenciais_dest(V_2, R2, vaz_D2, B2, Fdest2, L2, M2,
x2, y2, z2);

%Integrando

x2novo = x2 + dX2.*(passo);
M2novo = M2 + dM2.*(passo);

x2 = x2novo;
M2 = M2novo;

integra2 = integra2+1;
end
%
%
% %%Perturbações
    incr_RR2 = 0;
    incr_F2 = 0;
    incr_z2 = 0;
    if tempo >= 1
        if cont5 == 10/tmc %divide por 0.01 pra igualar com o tempo
            incr_RR2 = RR2*(-0.3 + (0.6)*rand);
            cont5 = 0;
        end
        if cont6 == 20/tmc %divide por 0.01 pra igualar com o tempo
            incr_F2 = Fdest2*(-0.3 + (0.6)*rand);
            cont6 = 0;
        end
        if cont7 == 40/tmc %divide por 0.01 pra igualar com o tempo
            incr_z2 = z2*(-0.1 + (0.2)*rand);
            cont7 = 0;
        end
        cont5 = cont5+1;
        cont6 = cont6+1;
        cont7 = cont7+1;
    end
    RR2 = RR2 + incr_RR2;
    Fdest2 = Fdest2 + incr_F2;
    z2 = z2 + incr_z2;
% restrição das pretubações

```

```

    if RR2 > 0.9
        RR2 = 0.5;
    elseif RR2 < 0.1
        RR2 = 0.5;
    end
    if Fdest2 > 100
        Fdest2 = 50;
    elseif Fdest2 < 20
        Fdest2 = 50;
    end
    if z2 > 0.8
        z2 = 0.4;
    elseif z2 < 0.08
        z2 = 0.4;
    end
end

tempo = tempo + tmc

i = int;

%-----Armazenamento de dados destilação-----
VD1(i) = vaz_D1;
VR1(i) = R1;
VRR1(i) = RR1;
VF1(i) = Fdest1;
Vz1(i) = z1;
Vx1(i,:) = x1;
temperatura_col_1(i,:) = t1;
vapor(i,:) = V_1;
x8 = x1(8);
Vx1_8 = Vx1(:,8);
plota2 = Vx1_8;

VD2(i) = vaz_D2;
VR2(i) = R2;
VRR2(i) = RR2;
VF2(i) = Fdest2;
Vz2(i) = z2;
Vx2(i,:) = x2;
temperatura_col_2(i,:) = t2;
Vx2_8 = Vx2(:,8);
Vtempo(i,:) = tempo;
%-----Saída da etapa de perturbação-----

%-----Etapa de controle da destilação-----
if tempo == 5
    set_dest = 0.2;
end
if tempo == 50
    set_dest = 0.35;
end
if tempo == 100
    set_dest = 0.25;
end

%PID destilação 1

```

```

if tempo >=5
e1 = Vx1_8(int) - set_dest;           % e(k)
e2 = Vx1_8(int-1) - set_dest;        % e(k-1)
e3 = Vx1_8(int-2) - set_dest;
eint = sum((Vx1_8(int-5:int) - set_dest)*0.5);

Kp = 5;
Ki = 10;
Kd = 0.2;
RR1_corr = Kp*((e1) + (1/Ki)*(eint) + ((Kd)*(e1-e2)/0.5));
RR1 = RR1 - RR1_corr;
end
    if RR1 > 0.9
        RR1 = 0.9;
    elseif RR1 < 0.1
        RR1 = 0.1;
    end
end

if tempo == 5
    set_dest = 0.2;
end
if tempo == 50
    set_dest = 0.35;
end
if tempo == 100
    set_dest = 0.25;
end

%PID destilação 1
    %kc=0.0029
    %Pc = 26

if tempo >=5
e1 = Vx1_8(int) - set_dest;           % e(k)
e2 = Vx1_8(int-1) - set_dest;        % e(k-1)
e3 = Vx1_8(int-2) - set_dest;
eint = sum((Vx1_8(int-5:int) - set_dest)*0.5);

Kp = 5;
Ki = 10;
Kd = 0.2;
RR1_corr = Kp*((e1) + (1/Ki)*(eint) + ((Kd)*(e1-e2)/0.5));
RR1 = RR1 - RR1_corr;
end
    if RR1 > 0.9
        RR1 = 0.9;
    elseif RR1 < 0.1
        RR1 = 0.1;
    end
end

% Controle Preditivo destilação 1
if tempo >= 5
    if conta_dest1 == 1 %aplica o controle numa instância determinada de
tempo.
        Nu_dest = 1;
    end
end

```

```

        Ny_dest = 20;
        u = ones(1,Nu_dest).*RR1;
        lb = 0.1;
        ub = 0.9;

%         options = optimset('Display','iter');
        u =
fmincon('otimizador_dest1',u,[],[],[],[],ones(1,Nu_dest).*lb,ones(1,Nu_dest).
*ub); %vazão de refluxo
        RR1 = u(1);
        conta_dest1 = 0;
        end
        conta_dest1 = conta_dest1+1;
end

% CCONTROLE DDESTILACAO 2
if tempo == 5
    set_dest2 = 0.4;
end

% PID destilação 2
if tempo >=5
    kc=0.0029
    Pc = 26
    e1 = Vx2_8(int) - set_dest2;           % e(k)
    e2 = Vx2_8(int-1) - set_dest2;       % e(k-1)
    e3 = Vx2_8(int-2) - set_dest2;
    eint = sum((Vx2_8(int-2:int) - set_dest2)*0.5);

    Kp = 3;
    Ki = 5;
    Kd = 0.1;
    RR2_corr = Kp*((e1) + (1/Ki)*(eint) + ((Kd)*(e1-e2)/0.5));
    RR2 = RR2 - RR2_corr;

end
    if RR2 > 0.9
        RR2 = 0.9;
    elseif RR2 < 0.1
        RR2 = 0.1;
    end

set = [];
for i = 1:1:80
    set(i) = 0.12;
end
for i = 81:1:160
    set(i) = 0.3;
end
% Controle Preditivo destilação 2
%
if tempo >= 5
    if conta == 1 %aplica o controle numa instancia determinada de
tempo.
        Nu_dest2 = 2;

```

```

        Ny_dest2 = 5;
        u2 = ones(1,Nu_dest2).*RR2;
        lb = 0.1;
        ub = 0.9;
    %
        options = optimset('Display','iter');
        u =
fmincon('otimizador_dest2',u2,[],[],[],[],ones(1,Nu_dest2).*lb,ones(1,Nu_dest
2).*ub);
        RR2 = u(1);
        conta = 0;
    end
    conta = conta+1;
end

% fim do preditivo

% contador de iterações
int = int+1;

% fim do loop
end

IEA_dest2 = sum(abs(0.5*Vx2_8(80:100)));
IEA_dest1 = sum(abs(0.5*Vx1_8(80:100)));

%-----Discretização dos dados-----

Vtempo = Vtempo'; % deixar tudo como coluna
passod = 50; %exclui um intervalo de passod de dados
vard = ts*100/passod-1;

P4vd = P4v;
SoVd = SoV;
tx_rVd = tx_rV;
i = 1;

while i < vard
    P4vd((i+1:(passod+i))) = [];
    SoVd((i+1:(passod+i))) = [];
    tx_rVd((i+1:(passod+i))) = [];
    i = i+1;
end

Vx1 = Vx1'; %destilação 1
Vx81 = Vx1(8,:);
i = 1;
Vtempod = Vtempo;
    VDd1 = VD1;
    VRd1 = VR1;
    VFd1 = VF1;
    Vz1 = Vz1;
    Vx8d1 = Vx81;

while i < vard
    Vtempod(i+1:(passod+i)) = [];

```

```

        VDd1((i+1:(passod+i))) = [];
        VRd1((i+1:(passod+i))) = [];
        VFd1((i+1:(passod+i))) = [];
        Vzdz1((i+1:(passod+i))) = [];
        Vx8d1(:, (i+1:(passod+i))) = [];
        i = i+1;
end

i = 1;          %destilação 2
Vx2 = Vx2';
Vx82 = Vx2(8,:);
        VDd2 = VD2;
        VRd2 = VR2;
        VFd2 = VF2;
        Vzdz2 = Vz2;
        Vx8d2 = Vx82;
while i < vard
        VDd2((i+1:(passod+i))) = [];
        VRd2((i+1:(passod+i))) = [];
        VFd2((i+1:(passod+i))) = [];
        Vzdz2((i+1:(passod+i))) = [];
        Vx8d2(:, (i+1:(passod+i))) = [];
        i = i+1;
end

% fim da discretização
%-----
%geração dos dados de k-1 e k-2 para o treinamento da rede
P4sai = P4v;
P4sai(1:2) = [];
P4_k1 = P4v;
P4_k1(1) = [];
P4_k2 = P4v;
SoV_k1 = SoV;
SoV_k1(1) = [];
tx_k1 = tx_rV;
tx_k1(1) = [];
%igualar o tamanho dos vetores (verificar o tamanho de cada um)
tam = size(P4v);
tam = tam(1);

tx_k1(tam-1) = [];
P4_k1 (tam-1) = [];
P4_k2 (tam-1:tam) = [];
SoV_k1 (tam-1) = [];

entrada = [tx_k1, P4_k1,P4_k2, SoV_k1]';% taxa de refulxo, valor atual,
valor anterior e concentração de substrato
saida = [P4sai]';
% entrada = [tx_rV, P4_k1, SoV]';%P4_k2,, taxa de refulxo, valor atual, valor
anterior e concentração de substrato
% saida = [P4sai]';% valor futuro
%[sai_teste_nor,Yrr, net_ferm]=rede_ferm(entrada,saida);

P4_k1 = P4_k1';
P4_k2 = P4_k2';

```

```

P4sai = P4sai';
SoV_1 = SoV_k1';
tx_rV_1 = tx_k1';

% [f,PFa] = mapminmax(FaV_1);
[tx,Ptx] = mapminmax(tx_rV_1);
[s_1,PP4] = mapminmax(P4_k1);
[s_2,PP4_2] = mapminmax(P4_k2);
[sai,PP4_sai] = mapminmax(P4sai);
[so,PSo] = mapminmax(SoV_1);

entrada = [tx; s_1;s_2; so];%, taxa de refluxo, valor atual, valor anterior e
concentração de substrato
saida = [sai];

net_ferm = feedforwardnet(5, 'trainbr');
net_ferm = train(net_ferm,entrada,saida);

%-----treino da DESLITAÇÃO 1-----
%geração dos dados de k-1 e k-2 para o treinamento da rede
x1_k2 = Vx1(:,8);
x1sai = Vx1(:,8);
x1sai(1:2) = [];
x1_k1 = Vx1(:,8);
x1_k1(1) = [];
z1_k1 = Vz1;
z1_k1(1) = [];
RR1_k1 = VRR1;
RR1_k1(1) = [];
FVT_k1 = VF1;
FVT_k1(1) = []; %vazão vinho deslevedurado após a centrífuga
%igual a o tamanho dos vetores (verificar o tamanho de cada um)
tam = size(Vx1);
tam = tam(1);

RR1_k1(tam-1) = [];
x1_k1 (tam-1) = [];
x1_k2 (tam-1:tam) = [];
z1_k1 (tam-1) = [];
FVT_k1 (tam-1) = [];

% Treinamento da rede (rodar depois do programa)
% define as entrada e saídas da rede
x1_k1 = x1_k1';
x1_k2 = x1_k2';

RR1_k1(1:60) = [];
x1_k1(1:60) = [];
x1_k2(1:60) = [];
z1_k1(1:60) = [];
x1sai(1:60) = [];
FVT_k1(1:60) = [];

%normalização

```

```

[VRn,PRR1] = mapminmax(RR1_k1);
[Vzn,Pz1] = mapminmax(z1_k1);
[Vxn,Px1] = mapminmax(x1_k2);
[Vfvt,Pfvt] = mapminmax(FVT_k1);

%treinamento da rede
un = mapminmax('apply',RR1_k1,PRR1);
xn_1= mapminmax('apply',x1_k1,Px1);
xn_2= mapminmax('apply',x1_k2,Px1);
zn = mapminmax('apply',z1_k1,Pz1);
x1_sai = mapminmax('apply',x1sai,Px1);
fvt = mapminmax('apply',FVT_k1,Pfvt);

entrada = [un; xn_1; xn_2; zn; fvt];
saida = x1_sai';

net_dest1 = feedforwardnet(10, 'trainbr');
net_dest1 = train(net_dest1,entrada,saida);

%treina a rede chamando o arquivo 'rede', ajustar o arquivo com o tamanho
%dos dados
%[sai_teste_nor,Yrr,net_dest] = rede(entrada,saida)

%normalização dos dados, utilizada apenas no MPC

%-----treino da DESLITAÇÃO 2-----
%geração dos dados de k-1 e k-2 para o treinamento da rede
x2_k2 = Vx2(:,8);
x2sai = Vx2(:,8);
x2sai(1:2) = [];
x2_k1 = Vx2(:,8);
x2_k1(1) = [];
z2_k1 = Vz2;
z2_k1(1) = [];
RR2_k1 = VRR2;
RR2_k1(1) = [];
% D1_k1 = VD1;
D1_k1 = VF2;
D1_k1(1) = [];
%igualar o tamanho dos vetores (verificar o tamanho de cada um)
tam = size(Vx1);
tam = tam(1);

RR2_k1(tam-1) = [];
x2_k1(tam-1) = [];
x2_k2(tam-1:tam) = [];
z2_k1(tam-1) = [];
D1_k1(tam-1) = [];

% Treinamento da rede (rodar depois do programa)
% define as entrada e saídas da rede
x2_k1 = x2_k1';
x2_k2 = x2_k2';

```

```

RR2_k1(1:60) = [];
x2_k1(1:60) = [];
x2_k2(1:60) = [];
z2_k1(1:60) = [];
x2sai(1:60) = [];
D1_k1(1:60) = [];

%normalização
[VRn, PRR2] = mapminmax(RR2_k1);
[Vzn, Pz2] = mapminmax(z2_k1);
[Vxn, Px2] = mapminmax(x2_k2);
[Vdn, PD1] = mapminmax(D1_k1);

%treinamento da rede
un = mapminmax('apply', RR2_k1, PRR2);
xn_1= mapminmax('apply', x2_k1, Px2);
xn_2= mapminmax('apply', x2_k2, Px2);
zn = mapminmax('apply', z2_k1, Pz2);
x2_sai = mapminmax('apply', x2sai, Px2);
dn = mapminmax('apply', D1_k1, PD1);

entrada = [un; xn_1; xn_2; zn; dn];
saida = x2_sai';

net_dest2 = feedforwardnet(10, 'trainbr');
net_dest2 = train(net_dest2, entrada, saida);

```

CÁLCULO DAS EQUAÇÕES DIFERENCIAIS DAS DESTILAÇÕES

```

function [dM,dX] = calculo_diferenciais_dest(V, R, D, B, F, L, M, x, y, z)
%-----Calculando as diferenciais-----
dM(8) = V(7) - R - D; %V(7) = vapor no topo
%retido no condesador
dX(8) = (V(7)*y(7) - R*x(8) - D*x(8))/M(8);
%fração de liquido x1 no condesador (condesador total)
dM(7) = R - L(7) + V(5) - V(7);
dX(7) = (R*x(8) - L(7)*x(7) + V(5)*y(6) - V(5)*y(7))/(M(7));
%V(6) = vapor na seção de retificação

%-----na seção de retificação-----
dM(6) = L(7) - L(6);
dX(6) = (L(7)*x(7) - L(6)*x(6) + V(5)*y(5) - V(5)*y(6));
dX(6) = dX(6)./M(6);

%-----derivadas do prato de alimentação-----
dM(5) = L(6) - L(5) + V(1) - V(5) + F;
dX(5) = (L(6)*x(6) - L(5)*x(5) + V(1)*y(4) - V(5)*y(5) + F*z)/M(5);
%onde F é a vazao de alimentação e z é a composição

%do produto 1 (metanol), na alimentação
%-----na seção de esgotamento-----
for i = 2:4
%calcula as derivadas nos estágios 2-4.
    dM(i) = L(i+1) - L(i);
    dX(i) = (L(i+1).*x(i+1) - L(i).*x(i) + V(1).*y(i-1) - V(1).*y(i));
    dX(i) = dX(i)./M(i);
end

```

```
end
```

```
%-----derivadas da base-----
```

```
dM(1) = L(2) - V(1) - B;  
dX(1) = (L(2)*x(2) - V(1)*y(1) - B*x(1))./M(1);
```

BALANÇO DE ENERGIA NO ESTÁGIO DE TOPO DAS DESTILAÇÕES

```
function Qtopo = balanco_energia_topo_dest(x, t, W, Z)
global n_estagios

MM1 = W(5);           %massa molar do met
MM2 = Z(5);           %massa molar da agua
CP1 = W(6);           %calor especifico de 1 (j/g.k)
CP2 = Z(6);           %calor especifico de 2 (j/g.k)
HV1 = W(4);           %calor latente de 1 (j/g)
HV2 = Z(4);           %calor latente de 2 (j/g)

%balanço de energia do topo
XM1 = x(n_estagios)*MM1;
XM2 = (1-x(n_estagios))*MM2;
XM3 = XM1 + XM2;

%frações mássicas para cada componente
FM1 = XM1/XM3;
FM2 = XM2/XM3;

%calor especifico da mistura
CPM = CP1*FM1 + CP2*FM2;

%calor latente da mistura
HVM = HV1*FM1 + HV2*FM2;

%diferença entre a temperatura do prato de topo e a temperatura do refluxo
%que é sub-resfriado
delta = t(n_estagios) - 320;

%percentual que relaciona a quantidade de vapor condensado com a vazao de
%refluxo.
Qtopo = (CPM*delta)/HVM;
```

BALANÇO DE ENERGIA DA ALIMENTAÇÃO DAS DESTILAÇÕES

```
function QF = balanco_energia_alimentacao_dest(x, t, W, Z)
global p_feed;
MM1 = W(5);           %massa molar do met
MM2 = Z(5);           %massa molar da agua
CP1 = W(6);           %calor especifico de 1 (j/g.k)
CP2 = Z(6);           %calor especifico de 2 (j/g.k)
HV1 = W(4);           %calor latente de 1 (j/g)
HV2 = Z(4);           %calor latente de 2 (j/g)
```

```

%frações
XM1 = x(p_feed)*MM1;
XM2 = (1-x(p_feed))*MM2;
XM3 = XM1 + XM2;
%frações mássicas para cada componente
FM1 = XM1/XM3;
FM2 = XM2/XM3;

%calor específico da mistura
CPM = CP1*FM1 + CP2*FM2;

%calor latente da mistura
HVM = HV1*FM1 + HV2*FM2;

%diferença entre a temperatura do prato de topo e a temperatura do refluxo
%que é sub-resfriado
delta = t(p_feed) - 330; %330 é a temperatura de alimentação (líquido sub-
resfriado)

%percentual que relaciona a quantidade de vapor condensado com a vazao de
%refluxo.
QF = (CPM*delta)/HVM;

```

CALIBRAÇÃO REFERVEDOR DAS DESTILAÇÕES

```

function V = calibracao_reboiler_dest(x, VV, W, Z)
%Esta função faz o cálculo da calibração do reboiler, convertendo a vazão
%de alimentação de vapor no reboiler (VV) em quantidade de vapor que deixa
%o reboiler (V)
%propiedades termodinamicas

MM1 = W(5);
MM2 = Z(5);
HL1 = W(4); %Calor lantente para o leve (j/g)
HL2 = Z(4); %Calor lantente para o pesado
HL3 = 2238; %Calor latente do vapor que alimento o reboiler

VR = (0.0066*(VV) + 0.1426)*1000;
%entrada de calor no reboiler
H = VR*HL3;
XM1 = x(1)*MM1;
XM2 = (1-x(1))*MM2;
XM3 = XM1 + XM2;
%fração mássica para os compostos
FM1 = XM1/XM3;
FM2 = XM2/XM3;
%calor latente da mistura
CM = HL1*FM1 + HL2*FM2;
%Fluxo de vapor que deixa o reboiler(g/min)
FV = H/CM;
%Fluxo de vapor que deixa o reboiler(mol/min)
FV = FV/XM3;
V(1) = FV;

```

SIMULAÇÃO RECURSIVA PARA A FERMENTAÇÃO

```

Xp = [];
timee = [];
un = [];
xn_1 = [];
xn_1 = [];
xn_2 = [];
zn = [];

un = mapminmax('apply',tx_rV_1,Ptx);
xn_1= mapminmax('apply',P4_k1 ,PP4);
xn_2= mapminmax('apply',P4_k2,PP4);
zn = mapminmax('apply',SoV_1,PSo);

%simula a rede, gerando os valores de predição Y em um vetor de tamanho Ny

xn_2_in = xn_2(1);
xn_1_in = xn_1(1);
for i = 1:1:1000
entrada_r = [un(i); xn_1_in; xn_2_in; zn(i)];
Xn = sim(net_ferm,entrada_r);

xn_2_in = xn_1_in;
xn_1_in = Xn;

Xp(:,i) = Xn;
timee(:,i) = i;
end
timee = timee.*0.5;
plot(timee, Xp, timee, xn_1(1:1000))

```

SIMULAÇÃO RECURSIVA PARA A DESTILAÇÃO 1

```

Xp = [];
timee = [];
un = [];
xn_1 = [];
xn_1 = [];
xn_2 = [];
zn = [];
fvt = [];
un = mapminmax('apply',RR1_k1,PRR1); %variável manipulada
xn_1= mapminmax('apply',x1_k1,Px1); %variável controlada
xn_2= mapminmax('apply',x1_k2,Px1);
zn = mapminmax('apply',z1_k1,Pz1); %distúrbio
fvt = mapminmax('apply',FVT_k1,Pfvt);
%simula a rede, gerando os valores de predição Y em um vetor de tamanho Ny

xn_2_in = xn_2(1);
xn_1_in = xn_1(1);
for i = 1:1:1000
entrada_r = [un(i); xn_1_in; xn_2_in; zn(i); fvt(i)];
Xn = sim(net_dest1,entrada_r);

```

```
xn_2_in = xn_1_in;
xn_1_in = Xn;
```

```
Xp(:,i) = Xn;
timee(:,i) = i;
end
```

SIMULAÇÃO RECURSIVA PARA A DESTILAÇÃO 2

```
Xp = [];
timee = [];
un = [];
xn_1 = [];
xn_1 = [];
xn_2 = [];
zn = [];
un = mapminmax('apply',RR2_k1,PRR2);
xn_1= mapminmax('apply',x2_k1,Px2);
xn_2= mapminmax('apply',x2_k2,Px2);
zn = mapminmax('apply',z2_k1,Pz2);
dn = mapminmax('apply',D1_k1,PD1);
%simula a rede, gerando os valores de predição Y em um vetor de tamanho Ny

xn_2_in = xn_2(1);
xn_1_in = xn_1(1);
for i = 1:1:1000
entrada_r = [un(i); xn_1_in; xn_2_in; zn(i); dn(i)];
Xn = sim(net_dest2,entrada_r);

xn_2_in = xn_1_in;
xn_1_in = Xn;

Xp(:,i) = Xn;
timee(:,i) = i;
end
plot(timee, Xp, timee, xn_1(1:1000))
```

CONTROLE MPC E DMPC PARA A FERMENTAÇÃO

```
function J = otimizador_ferm(u)
global P4v; global Nu_ferm; global Ny_ferm; global set_ferm;
global So; global PSo; global net_ferm; global PP4; global Ptx
lambda = 0; global int; global tx_r; global y_Ny_ferm
% u = tx_r + u_diff;

%igualar o tamanho dos vetores u e y para a utilização na rede neural
for i = Nu_ferm:1:Ny_ferm
u(i) = u(Nu_ferm); %0;
end

% normaliza os dados de entrada da rede neural

un = mapminmax('apply',u,Ptx);
```

```

Son = mapminmax('apply',So,PSo);
P4n_1 = mapminmax('apply',P4v(int),PP4);
P4n_2 = mapminmax('apply',P4v(int-1),PP4); %-1 porque a rede foi treinada
dados discretizados a cada 50 pontos

%simula a rede, gerando os valores de predição Y em um vetor de tamanho Ny
entradan = un;
for i = 1:1:Ny_ferm
entrada_r = entradan(1,i);
entrada_r = [entrada_r; P4n_1; P4n_2; Son];
P4n = sim(net_ferm,entrada_r);

P4n_2 = P4n_1;
P4n_1 = P4n;

P4p(:,i) = P4n;
timee(:,i) = i;
end
y_Ny_ferm = mapminmax('reverse',P4p,PP4);
Ey = sum((y_Ny_ferm - set_ferm).^2);
Eu = sum((u).^2)*lambda;
J = (Eu + Ey)

```

CONTROLE MPC E DMPC PARA A DESTILAÇÃO 1

```

function J = otimizador_dest1(u)
global net_dest1; global z1; global y_Ny_ferm
global PRR1; global Pz1; global Px1; global Vx1_8
global Nu_dest; global Ny_dest; global set_dest; global int
global y_Ny_dest1; global FVT; global Pfvt

lambda = 0;

z1_trajetoria = y_Ny_ferm/1000;

for i = Nu_dest:1:Ny_dest
u(i) = u(Nu_dest); %0;
end
for i = 1:1:Ny_dest
% z_1(i) = z1; %MPC
f_1(i) = FVT;
z_1(i) = z1_trajetoria(i); %DMPC
end

%parcela distribuída

%normaliza os dados de entrada da rede neural
un = mapminmax('apply',u,PRR1); %variável manipulada
xn_1= mapminmax('apply',Vx1_8(int),Px1); %variável controlada
xn_2= mapminmax('apply',Vx1_8(int-1),Px1);
zn = mapminmax('apply',z_1,Pz1); %distúrbio
fvtn = mapminmax('apply',f_1,Pfvt);%distúrbio

```

```
%simula a rede, gerando os valores de predição Y em um vetor de tamanho Ny
```

```
for i = 1:1:Ny_dest
    entrada_r = [un(i); xn_1; xn_2; zn(i); fvtm(i)];
    Xn = sim(net_dest1,entrada_r);

    xn_2 = xn_1;
    xn_1 = Xn;

    Xp(:,i) = Xn;
    timee(:,i) = i;
end
y_Ny_dest1 = mapminmax('reverse',Xp,Px1);
Ey = sum((y_Ny_dest1 - set_dest).^2);
Eu = sum((un.*lambda).^2);
J = (Eu + Ey)/Ny_dest
```

CONTROLE MPC E DMPC PARA A DESTILAÇÃO 2

```
function J = otimizador_dest2(u)
global net_dest2; global z2; global vaz_D1
global PRR2; global Pz2; global Px2; global Vx2_8; global PD1
global Nu_dest2; global Ny_dest2; global set_dest2; global int
global y_Ny_dest1;
lambda = 0;
for i = Nu_dest2:1:Ny_dest2
    u(i) = u(Nu_dest2); %0;
end
for i = 1:1:Ny_dest2
    % D_1(i) = vaz_D1; %MPC
    z_2(i) = y_Ny_dest1(i); %DMPC
    z_2(i) = z2; %MPC
end
%parcela distribuída
%z_2(i) = predicao_fermentacao(int-Ny_dest:int);
%normaliza os dados de entrada da rede neural
un = mapminmax('apply',u,PRR2);
xn2_1= mapminmax('apply',Vx2_8(int),Px2);
xn2_2= mapminmax('apply',Vx2_8(int-1),Px2);
zn_2 = mapminmax('apply',z_2,Pz2);
dn = mapminmax('apply',D_1,PD1);
%simula a rede, gerando os valores de predição Y em um vetor de tamanho Ny
for i = 1:1:Ny_dest2
    entrada_r = [un(i); xn2_1; xn2_2; zn_2(i); dn(i)];
    Xn = sim(net_dest2,entrada_r);
    xn2_2 = xn2_1;
    xn2_1 = Xn;
    Xp(:,i) = Xn;
    timee(:,i) = i;
end
y_Ny2 = mapminmax('reverse',Xp,Px2);
Ey = sum((y_Ny2 - set_dest2).^2);
Eu = sum((un.*lambda).^2);
J = (Eu + Ey)/Ny_dest2;
```