



UFBA

UNIVERSIDADE FEDERAL DA BAHIA
ESCOLA POLITÉCNICA
PROGRAMA DE PÓS GRADUAÇÃO EM
ENGENHARIA INDUSTRIAL - PEI

MESTRADO EM ENGENHARIA INDUSTRIAL

Carolina de Azerêdo Amaro

**Modelagem Dinâmica e Detecção de Falhas
em um Sistema de Desetanização de uma
Unidade de Recuperação de Gás Natural**



**SALVADOR
2013**



MODELAGEM DINÂMICA E DETECÇÃO DE FALHAS EM UM SISTEMA DE DESETANIZAÇÃO DE UMA UNIDADE DE RECUPERAÇÃO DE GÁS NATURAL

Carolina de Azerêdo Amaro

Dissertação de Mestrado apresentada ao Programa de Pós-graduação em Engenharia Industrial, da Universidade Federal da Bahia, como parte dos requisitos necessários à obtenção do título de Mestre em Engenharia Industrial.

Orientadores:

Prof. Marcelo Embiruçu

Profa. Karen Pontes

Profa. Isabel Sartori

SALVADOR

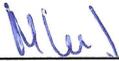
Novembro de 2013

Modelagem Dinâmica e Detecção de Falhas em um Sistema de Desetanização de uma Unidade de Recuperação de Gás Natural

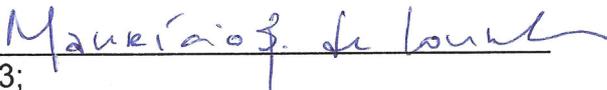
CAROLINA DE AZERÊDO AMARO

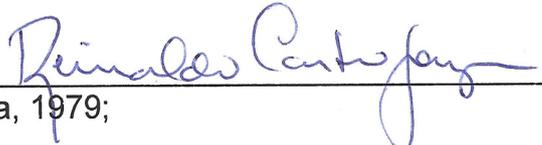
Dissertação submetida ao corpo docente do programa de pós-graduação em Engenharia Industrial da Universidade Federal da Bahia como parte dos requisitos necessários para a obtenção do grau de mestre em Engenharia Industrial.

Examinada por:

Prof. Marcelo Embiruçu 
Doutor em Engenharia Química, Brasil, 1998;

Prof. Carlos Arthur Mattos Teixeira Cavalcante 
Doutor em Engenharia de Produção, Brasil, 1999;

Prof. Mauricio Bezerra de Souza Junior 
Doutor em Engenharia Química, Brasil, 1993;

Prof. Reinaldo Castro Souza 
Doutor em Estatística, Inglaterra, 1979;

Salvador, BA - BRASIL
novembro/2013

Conforme resolução do Programa, o conjunto de orientadores teve a representação de 1 (um) único voto no parecer final da banca examinadora.

A585 Amaro, Carolina de Azeredo.

Modelagem dinâmica e detecção de falhas em um sistema de desetanização de uma unidade de recuperação de gás natural / Carolina de Azerêdo Amaro. – Salvador, 2013.

81f. : il. color.

Orientador: Prof. Marcelo Embiruçu

Co-orientadora: Profa. Karen Valverde Pontes

Co-orientadora: Profa. Isabel Sartori

Dissertação (mestrado) – Universidade Federal da Bahia. Escola Politécnica, 2013.

1. Gás natural. 2. Modelagem dinâmica. 3. Sistema de desetanização. 4. Falhas - detecção. I. Embiruçu, Marcelo. II. Pontes, Karen Valverde. III. Sartori, Isabel. IV. Universidade Federal da Bahia. V. Título.

CDD: 622.3385

À minha amada avó Nair.

Agradecimentos

À minha família por todo suporte e amor oferecidos, a meu namorado e companheiro, Júnior, pelo apoio em todos os momentos, e aos amigos que sempre me motivaram nos momentos de dificuldade, Marcos, Reiner, Robson e Raony. Meus agradecimentos também aos companheiros de pesquisa Vítor Emmanuel e Victor Bouzas pela parceria e aprendizado.

Aos meus orientadores, Marcelo Embiruçu, Karen Pontes e Isabel Sartori, pela confiança, ajuda e, principalmente, paciência.

Ao Eng. Jorge Francisco pela oportunidade e orientação técnica.

Ao agora Prof. Edson Valle por toda a ajuda nas dificuldades encontradas com o EMSO.

Ao Programa de Engenharia Industrial da Universidade Federal da Bahia, seus coordenadores, professores e funcionários, pela dedicação e oportunidade.

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pelo apoio financeiro na realização deste trabalho.

Um muito obrigado especial a Isabel e Flávia, pela força e amizade, acima de tudo!

E por fim, a todos que contribuíram de alguma forma para a realização deste trabalho, meus sinceros agradecimentos.

Resumo da Dissertação apresentada ao PEI/UFBA como parte dos requisitos necessários para a obtenção do grau de Mestre em Ciências (M.Sc.)

MODELAGEM DINÂMICA E DETECÇÃO DE FALHAS EM UM SISTEMA DE DESETANIZAÇÃO DE UMA UNIDADE DE RECUPERAÇÃO DE GÁS NATURAL

Sistemas de Detecção, Diagnóstico e Correção de Falhas (FDDC, *Fault, Detection, Diagnosis and Correction*) aplicados a sistemas industriais são cada vez mais importantes devido à crescente demanda por processos confiáveis, eficientes e automatizados. Dentro do setor industrial, o processamento de gás natural tem ganhado destaque em virtude do aumento de sua importância no setor energético brasileiro e mundial. Assim, garantir a especificação dos produtos e aumentar a segurança e a confiabilidade da planta, além de reduzir os custos envolvidos no processo, são alguns dos principais benefícios almejados pelas indústrias com a implementação de sistemas de FDDC. Portanto, o principal objetivo desta dissertação é desenvolver um sistema de FDDC para uma coluna desetanizadora de uma unidade de processamento de gás natural capaz de monitorar a planta em tempo real e, além das etapas de detecção e diagnóstico, realizar a etapa de correção de forma automática. Um modelo matemático da coluna foi construído no simulador de processos EMSO e utilizado na geração de dados de falha. O sistema FDDC foi construído no MATLAB/Simulink para falhas no sensor de temperatura da malha de controle do refeedor. Primeiramente o sistema foi desenvolvido com um algoritmo simples com estruturas de decisão e, em seguida, foi utilizado um algoritmo com redes neurais treinadas a partir dos dados fornecidos pelo modelo dinâmico da coluna. A interligação do sistema FDDC (MATLAB/Simulink) com a coluna (EMSO) foi realizada através da interface de comunicação EMSO/Simulink disponível no EMSO. Em ambos os casos o sistema desenvolvido foi capaz de detectar todas as falhas e realizar uma ação de correção eficiente, capaz de evitar perda de desempenho da unidade, demonstrando como um sistema de FDDC adequado pode promover os benefícios elencados anteriormente.

Abstract of Dissertation presented to PEI/UFBA as a partial fulfillment of the requirements for the degree of Master of Science (M.Sc.)

DYNAMIC MODELING AND FAULT DETECTION IN A DEETHANIZER SYSTEM OF NATURAL GAS PROCESSING PLANT

Fault Detection, Diagnosis and Correction Systems (FDDC) applied to industrial systems are becoming increasingly important due to the growing demand for reliable, efficient and automated processes. The natural gas processing industry has gained increased attention due to its growing importance in the Brazilian and wide-world energy sector. So, ensuring products specification, increasing plant safety and reliability and reducing processing costs are some of the key benefits sought by the industry with the implementation of FDDC systems. Therefore, the main objective of this work is the development of a FDDC system for a deethanizer column of a natural gas processing plant which is capable of real time monitoring and, in addition to the steps of detection and diagnosis, performing also the step of automatically correction. A mathematical model of the column was built in process simulator EMSO and it was used to generate failure data. The FDDC system was implemented using MATLAB/Simulink for failures in the sensor of the reboiler temperature control loop. First the system was developed with a simple algorithm with decision logic structure and after a neural network trained with data provided by the column dynamic model then was used. The interconnection between the FDDC system (MATLAB/Simulink) with the column (EMSO) was carried through the EMSO/Simulink interface communication available in EMSO. In both cases the developed system was able to detect all faults and perform an efficient corrective action, avoiding unit performance loss and showing how a suitable FDDC system can promote the benefits listed above.

Índice

1. Introdução	1
1.1. OBJETIVOS	2
1.2. ORGANIZAÇÃO DA DISSERTAÇÃO	3
2. Revisão Bibliográfica	4
2.1. INDÚSTRIA DO GÁS NATURAL	4
2.2. DETECÇÃO, DIAGNÓSTICO E CORREÇÃO DE FALHAS.....	7
2.2.1. DENOMINAÇÕES E DEFINIÇÕES	9
2.2.2. PRINCIPAIS TAREFAS DE SISTEMAS DE FDDC.....	10
2.3. PRINCIPAIS TÉCNICAS EM FDDC	11
2.3.1. FDDC NA INDÚSTRIA DE PROCESSOS	15
2.4. SIMULAÇÃO DE PROCESSOS	16
3. Modelagem e Simulação	21
3.1. DESCRIÇÃO DO PROCESSO.....	21
3.2. DESETANIZAÇÃO	22
3.3. MODELAGEM DA COLUNA	24
3.4. RESULTADOS	36
4. Construção e Integração do Sistema de FDDC.....	40
4.1. SELEÇÃO DAS FALHAS	40
4.2. SIMULAÇÃO DAS FALHAS	42
4.3. DETECÇÃO, DIAGNÓSTICO E CORREÇÃO DAS FALHAS	47
4.3.1. ESTRUTURA DO SISTEMA E PADRÕES DE FALHA	49
4.3.2. ALGORITMO DE DECISÃO: DESENVOLVIMENTO E RESULTADOS	55
4.3.3. REDES NEURONAIIS: DESENVOLVIMENTO E RESULTADOS	59
5. Conclusões e Sugestões para Trabalhos Futuros	68
5.1. CONCLUSÕES.....	68
5.2. SUGESTÕES PARA TRABALHOS FUTUROS.....	72
6. Referências Bibliográficas.....	73

Lista de Figuras

Figura 2.1 - Principais atividades de sistemas de FDDC	11
Figura 3.1 - Processo básico da Unidade de Recuperação de Gás Natural	21
Figura 3.2 - Sistema de desetanização real.....	22
Figura 3.3 - Interface do simulador EMSO	24
Figura 3.4 - Desenho esquemático da coluna modelada no EMSO	28
Figura 3.5 - Desenho esquemático das malhas de controle implementadas.....	35
Figura 3.6 - Perfil de temperatura da coluna:valores simulado e real	37
Figura 3.7 - Simulação 1: Temperatura do LGN (a) e temperatura do gás de topo (b).....	38
Figura 3.8 - Simulação 2: Vazão molar de LGN produto (a) e taxa de calor para o refervedor (b)	38
Figura 4.1 - Simulação de falha no sensor de temperatura da saída líquida do refervedor.....	43
Figura 4.2 - Simulação de falha no transmissor de nível do vaso de topo	44
Figura 4.3 - Simulação de falha no transmissor de nível do refervedor	45
Figura 4.4 - Simulação de falha na válvula de refluxo da coluna	46
Figura 4.5 - Simulação de falha na válvula de saída do refervedor	47
Figura 4.6 - Configuração gráfica do usuário (GUI)	49
Figura 4.7 - Destaque da malha de controle de temperatura do refervedor.....	50
Figura 4.8 - Ilustração da comunicação EMSO/Simulink.....	51
Figura 4.9 - Falhas no sensor de temperatura: desvio (a) e rompimento (b).....	52
Figura 4.10 - Diferença entre as temperaturas dos sensores de saída do refervedor: padrão normal (N)	53
Figura 4.11 - Diferença entre as temperaturas dos sensores de saída do refervedor: padrão desvio (D)	53

Figura 4.12 - Diferença entre as temperaturas dos sensores de saída do refulvedor: padrão rompido (R)	54
Figura 4.13 - Pontos isolados no padrão normal (N).....	55
Figura 4.14 - Algoritmo da estrutura de decisão do sistema FDDC	56
Figura 4.15 - Desenho esquemático da comunicação processo/sistema FDDC.....	57
Figura 4.16 - Simulação integrada com falha Desvio (D): temperaturas marcadas pelos sensores de saída do refulvedor (a); diferença absoluta entre as temperaturas de saída e valor dos indicadores M e Z (b).....	58
Figura 4.17 - Simulação integrada com falha Rompido (R): temperaturas marcadas pelos sensores de saída do refulvedor (a); diferença absoluta entre as temperaturas de saída e valor dos indicadores M e Z (b).....	58
Figura 4.18 - Conjuntos de treinamento (a), validação (b) e teste (c) para a rede neuronal....	60
Figura 4.19 - Esquemático do sistema de FDDC desenvolvido com base em rede neuronal .	61
Figura 4.20 - Rede neuronal final do sistema FDDC	63
Figura 4.21 - Resultados da rede neuronal com pontos classificados de forma errada em destaque	64
Figura 4.22 - Simulação integrada (FDDC com rede neuronal) com padrão rompido (fim de escala): temperaturas marcadas pelos sensores de saída do refulvedor (a); diferença absoluta entre as temperaturas de saída e valor dos indicadores M e Z (b).....	66
Figura 4.23 - Simulação integrada (FDDC com rede neuronal) com padrão rompido (início de escala): temperaturas marcadas pelos sensores de saída do refulvedor (a); diferença absoluta entre as temperaturas de saída e valor dos indicadores M e Z (b).....	66
Figura 4.24 - Simulação integrada (FDDC com rede neuronal) com padrão desvio (-6,5 °C): temperaturas marcadas pelos sensores de saída do refulvedor (a); diferença absoluta entre as temperaturas de saída e valor dos indicadores M e Z (b)	67
Figura 4.25 - Simulação integrada (FDDC com rede neuronal) com padrão desvio (+3,0 °C): temperaturas marcadas pelos sensores de saída do refulvedor (a); diferença absoluta entre as temperaturas de saída e valor dos indicadores M e Z (b)	67

Lista de Tabelas

Tabela 3.1 - Especificações para estado estacionário da coluna desetanizadora.....	33
Tabela 3.2 - Composição molar da carga	34
Tabela 3.3 - Simulação 1: perturbação em degrau na temperatura da Alimentação 1	37
Tabela 3.4 - Simulação 2: perturbação em degrau na vazão da Alimentação 1	38

Lista de Quadros

Quadro 2.1 - Classificação das técnicas com base no conhecimento a priori utilizado	13
Quadro 3.1 - Pares PV-MV das malhas de controle.....	35
Quadro 4.1 - Falhas seleccionadas para simulação	41

Lista de Publicações

- Amaro, C., Requião, R. e Embiruçu, M. (2011). Dynamic Modeling of a Deethanizer Column in a Natural Gas Processing Plant. *International Proceedings of Computer Science and Information Technology*, v. 10, pp. 12–16.
- Sartori, I., Amaro, C. de A., Souza Júnior, M. B. de e Embiruçu, M. (2012). Detecção, Diagnóstico e Correção de Falhas: Uma Proposição Consistente de Definições e Terminologias. *Ciência & Engenharia*, v. 21, pp. 29–34.
- Sartori, I., Amaro, C. A., Arduini, F. Z., Souza Jr., M. B. de, Embiruçu, M. (2013). Fault Detection, Diagnosis and Correction in Industrial Processes: The Anatomy of Brazilian Research in the Global Context. *Ciência & Engenharia*, submetido.

Lista de Abreviaturas

ALSOC	Ambiente Livre para Simulação, Otimização e Controle de Processos
ANP	Agência Nacional do Petróleo, Gás Natural e Biocombustíveis
EAD	Equações algébrico-diferenciais
EKF	<i>Extended Kalman Filter</i>
EMSO	<i>Environment for Modeling, Simulation, and Optimization</i>
ES	<i>Expert System</i>
FDDC	<i>Fault Detection, Diagnosis and Correction</i>
FDI	<i>Fault Detection and Isolation</i>
GA	<i>Genetic Algorithm</i>
GLP	Gás Liquefeito de Petróleo
GUI	<i>Graphical User Interface</i>
HAZOP	<i>HAZard and OPerability study</i>
IEA	<i>International Energy Agency</i>
IFAC	<i>International Federation of Automatic Control</i>
KB	<i>Knowledge base</i>
LGN	Líquido de Gás Natural
MLP	<i>Multi-Layer Perceptron</i>
MV	<i>Manipulated Variable</i>
NN	<i>Neural Networks</i>
OCDE	Organização para a Cooperação e Desenvolvimento Econômico
OPEC	<i>Organization of the Petroleum Exporting Countries</i>
OPEP	Organização dos Países Exportadores de Petróleo
PCA	<i>Principal Component Analysis</i>
PDE	Plano Decenal de Expansão de Energia
PID	Proporcional-Integral-Derivativo

PLS	<i>Partial Least Squares</i>
PV	<i>Process Variable</i>
QPT	<i>Qualitative Process Theory</i>
QSIM	<i>Qualitative SIMulation</i>
QTA	<i>Qualitative Trend Analysis</i>
RAM	<i>Reliability, Availability and Maintainability</i>
SAFEPROCESS	<i>Symposium on Fault Detection, Supervision and Safety of Technical Processes</i>
SDG	<i>Signed Directed Graph</i>
SPC	<i>Statistical Process Control</i>
SVM	<i>Support Vector Machine</i>
UFBA	Universidade Federal da Bahia
UPGN	Unidade de Processamento de Gás Natural
URGN	Unidade de Recuperação de Gás Natural
VCD	Validação Cruzada Dinâmica

Lista de Símbolos

α	Coefficiente de queda de pressão no prato seco
β	Fator de aeração
ϕ_{liq}	Coefficiente de fugacidade do líquido
ϕ_{vap}	Coefficiente de fugacidade do vapor
ρ_{liq}	Massa específica da fase líquida (kg/m ³)
ρ_{vap}	Massa específica da fase vapor (kg/m ³)
Ah	Área total dos furos do prato (m ²)
A_{cross}	Área da seção transversal (m ²)
E	Energia interna do sistema (J)
E_{MV}	Eficiência de prato de Murphree
F_{in}	Vazão molar que entra no equipamento (mol/s)
F_{in}^l	Vazão molar de líquido que entra no equipamento (mol/s)
F_{in}^v	Vazão molar de vapor que entra no equipamento (mol/s)
F_{out}^l	Vazão molar de líquido que sai do equipamento (mol/s)
F_{out}^v	Vazão molar de vapor que sai do equipamento (mol/s)
$frac$	Fração de <i>split</i> da vazão
g	Aceleração da gravidade (m/s ²)
hw	Altura do vertedouro (m)
h_{in}	Entalpia da corrente que entra no equipamento (J/mol)
h_{in}^l	Entalpia da corrente de líquido que entra no equipamento (J/mol)
h_{in}^v	Entalpia da corrente de vapor que entra no equipamento (J/mol)
h_{out}^l	Entalpia da corrente de líquido que sai do equipamento (J/mol)
h_{out}^v	Entalpia da corrente de vapor que sai do equipamento (J/mol)
$Level$	Nível de líquido (m)
lw	Comprimento do vertedouro (m)
M^l	Acúmulo molar de líquido (mol)
M^v	Acúmulo molar de vapor (mol)
M_i	Acúmulo molar do componente i (mol)
N	Número de pratos da coluna

n	Número do prato
P_{in}	Pressão da corrente que entra do equipamento (atm)
P_{out}^l	Pressão da corrente de líquido que sai do equipamento (atm)
P_{out}^v	Pressão da corrente de vapor que sai do equipamento (atm)
Q	Taxa de calor (J/s)
T	Temperatura (K)
T_{in}	Temperatura da corrente que entra do equipamento (K)
T_{out}	Temperatura da corrente que sai do equipamento (K)
T_{out}^l	Temperatura de saída da corrente de líquido (K)
T_{out}^v	Temperatura de saída da corrente de vapor (K)
v	Fração vaporizada da corrente
v_{liq}	Volume molar da fase líquida (m^3/mol)
v_{vap}	Volume molar da fase vapor (m^3/mol)
V_{cond}	Volume do condensador (m^3)
V_{liq}	Volume de líquido no prato (m^3)
V_{ref}	Volume do refeedor (m^3)
V_{tray}	Volume do prato (m^3)
x	Fração molar no líquido
x_{in_i}	Fração molar do componente i na corrente de líquido que entra no equipamento
x_{out_i}	Fração molar do componente i na corrente de líquido que sai do equipamento
y_n^*	Fração molar do componente i na fase vapor em equilíbrio com a fase líquida
y_{in_i}	Fração molar do componente i na corrente de vapor que entra no equipamento
y_{out_i}	Fração molar do componente i na corrente de vapor que sai do equipamento
z_{in_i}	Fração molar do componente i na corrente que entra no equipamento
z_{out_i}	Fração molar do componente i na corrente que sai do equipamento

1. Introdução

A indústria mundial do gás natural tem apresentado índices significativos de crescimento, e reforça, a cada dia, sua posição de importante alternativa energética. Espera-se, até 2035, um crescimento da demanda global por energia superior a 30% em comparação ao nível atual, sendo China, Índia e Oriente Médio responsáveis por mais de 60% desse aumento (IEA, 2012). A demanda por energia nos países da Organização para a Cooperação e Desenvolvimento Econômico (OCDE) cresce pouco, mas há uma migração significativa do petróleo e do gás (e, em alguns casos, da energia nuclear) para o gás natural e para as energias renováveis.

O processamento de gás natural tem como principal objetivo garantir a especificação do gás para os consumidores finais do produto. Assim como na maioria das indústrias do cenário atual, existe uma necessidade de produzir com alta qualidade, de reduzir as taxas de rejeição do produto e de satisfazer leis que regulamentam questões ambientais e de segurança do trabalho. As tecnologias de controle e de monitoramento são aplicadas a processos a fim de se conseguir uma operação eficiente e segura, garantindo as necessidades anteriormente descritas. Como resultado da proposta do monitoramento do processo, o *downtime* (tempo em que a planta permanece indisponível) é minimizado, a segurança da operação da planta é melhorada, e os custos de processamento são reduzidos (Chiang *et al.*, 2001).

Os controladores de processo [controladores PID (Proporcional-Integral-Derivativo), controladores preditivos, entre outros], largamente utilizados nas indústrias de processamento, são projetados para compensar perturbações e manter o processo operando de forma satisfatória, porém existem certos tipos de perturbações de processo que não podem ser enfrentadas adequadamente por esses controladores que, além disso, também podem falhar, sendo essencial para isso os sistemas de detecção, diagnóstico e correção de falhas (FDDC, *Fault Detection, Diagnosis and Correction*).

Um sistema de FDDC pode garantir o aumento da vida útil do processo e a extensão do seu ciclo de vida, já que a detecção precoce da ocorrência de falhas é um fator crítico para evitar deterioração de produtos, degradação de desempenho e danos materiais e humanos (Blázquez e Miguel, 2005). Embora todas as tarefas de detecção, diagnóstico e correção possam, em princípio, ser implementadas de forma automática, isto nem sempre é necessário

(Chiang *et al.*, 2001). Por exemplo, a automação apenas dos procedimentos de detecção e isolamento de falha pode ser bastante útil para ajudar operadores e engenheiros a analisar, identificar e corrigir a falha, inserindo de forma mais eficiente o trabalho humano na malha de monitoramento e supervisão de processo, ao invés de automatizar o sistema inteiro.

Assim, a partir da disponibilidade de informações de uma planta de processamento de gás natural existente, seu sistema de desetanização foi escolhido para o estudo e desenvolvimento de um sistema de FDDC automático capaz de monitorar a planta industrial em tempo real e agir rapidamente sobre as falhas detectadas. Contudo, apesar de extremamente importantes, testes em plantas reais não são de fácil realização. Por isso, com o objetivo de entender o comportamento do processo em situações de falha, e suas reações às intervenções de correção, um modelo matemático representativo da planta foi construído no simulador de processos EMSO (*Environment for Modeling, Simulation, and Optimization*) (Soares e Secchi, 2003) e utilizado para a simulação de situações onde ocorrem falhas capazes de acionar o sistema de proteção (sistema de intertravamento) da planta.

1.1.OBJETIVOS

O objetivo geral desta dissertação é desenvolver um sistema automático de detecção, diagnóstico e correção de falhas para o sistema de desetanização de uma indústria real de processamento de gás natural. Com base neste objetivo geral, os seguintes objetivos específicos foram estabelecidos:

- Construir e validar um modelo dinâmico do sistema de desetanização de uma URGN (Unidade de Recuperação de Gás Natural) no EMSO;
- Selecionar e simular falhas que impactem no processo;
- Identificar os padrões das falhas selecionadas;
- Desenvolver um sistema de detecção, diagnóstico e correção de falhas, com etapa de correção automática, a partir de um algoritmo de decisão;
- Desenvolver um sistema de FDDC, a partir de histórico de dados fornecido pelo modelo dinâmico do processo, utilizando redes neurais, a fim de generalizar a aplicação desse tipo de sistema;

- Integrar ambos os sistemas desenvolvidos à simulação dinâmica do processo;
- Avaliar o comportamento do processo em resposta à interferência do sistema de FDDC.

1.2. ORGANIZAÇÃO DA DISSERTAÇÃO

Esta dissertação está dividida em cinco capítulos. Ao longo do texto, algumas palavras estrangeiras de difícil tradução e/ou de uso consagrado foram mantidas em sua forma original em tipo itálico, sendo colocado, na primeira aparição, o seu significado em língua portuguesa. Para a separação decimal optou-se por utilizar o ponto, e não a vírgula. No Capítulo 2, é apresentada uma revisão dos principais assuntos abordados neste trabalho:

- indústria de processamento do gás natural;
- detecção, diagnóstico e correção de falhas; e
- simulação de processos.

O simulador de processos utilizado, a modelagem da coluna desetanizadora e a simulação e validação do modelo dinâmico são apresentados no Capítulo 3. No Capítulo 4 são apresentadas as principais falhas registradas em colunas de separação, as falhas selecionadas para simulação no modelo desenvolvido em EMSO e a apresentação do estudo de caso usado no desenvolvimento do sistema de FDDC em Simulink/MATLAB (MathWorks, 2013a). Também é apresentada a ferramenta que permite a integração do EMSO com o Simulink, tornando possível ao sistema de FDDC monitorar o processo em tempo real. O sistema é desenvolvido, primeiramente, com um algoritmo de decisão e, posteriormente, com redes neurais. As conclusões do trabalho realizado estão apresentadas no Capítulo 5, juntamente com as perspectivas de futuros trabalhos a serem desenvolvidos no tema da dissertação.

2. Revisão Bibliográfica

2.1.INDÚSTRIA DO GÁS NATURAL

Considerado durante muitos anos apenas um subproduto da exploração e refino do petróleo, o gás natural tem se firmado como importante alternativa para a matriz energética do Brasil. O aumento da demanda na última década demonstra uma tendência crescente da participação do gás natural frente aos derivados do petróleo, principalmente nos setores industrial e termoeletrico.

O papel estratégico que os aspectos ambientais passaram a ter na produção de energia primária no mundo após a Conferência das Nações Unidas (RIO-92), o que foi reforçado depois da elaboração do Protocolo de Quioto (1997) e de sua ratificação em 2005, colocou o gás natural em destaque devido às suas menores taxas de emissão dos gases de efeito estufa (Vaz *et al.*, 2008).

Segundo relatórios da OPEP (Organização dos Países Exportadores de Petróleo; OPEC, *Organization of the Petroleum Exporting Countries*) e da IEA (*International Energy Agency*, agência internacional de energia), ambas as organizações projetam queda na participação dos combustíveis fósseis em detrimento dos renováveis, a liderança dos países da Ásia no crescimento da demanda e a substituição do petróleo por outras fontes de energia, em especial o gás natural. O aumento da participação relativa do gás natural deverá crescer dos atuais 22.6% para 26%, em 2035, em função do desenvolvimento do gás de xisto, da substituição do carvão na geração elétrica (visando à redução das emissões de carbono), e da expansão de seu uso no setor petroquímico (ANP, 2013b).

A Agência Nacional do Petróleo, Gás Natural e Biocombustíveis (ANP) estima que a produção de gás no Brasil deva crescer entre 5% e 6% ao ano até 2019, e a sua demanda em 2035 corresponderá a 31% da demanda da América Latina (ANP, 2013a). Em função das descobertas do pré-sal incluírem grandes volumes de gás associado, projeta-se que a produção brasileira passe de 15 bilhões de metros cúbicos em 2011 para 87 bilhões de metros cúbicos em 2035, aumento este que será direcionado primordialmente para o atendimento da demanda interna. As estimativas das reservas provadas de gás natural do Brasil foram mantidas em 500 bilhões de metros cúbicos ao final de 2012, mesmo volume estimado em 2011.

Em decorrência da expectativa de incremento do mercado de gás natural no país, novos investimentos estão previstos para o setor de gás natural. Segundo o Plano Decenal de Expansão de Energia [PDE 2021 (MME, 2012)], os investimentos serão da ordem de 1097 trilhões de reais no setor brasileiro de energia até 2021, sendo a maior fatia destinada para a indústria de petróleo e gás natural, com 749 bilhões de reais. Para os próximos anos, está previsto um investimento de 8 bilhões de reais somente na expansão da infraestrutura de gás natural, consistindo de ampliações e construções de novos gasodutos e unidades de processamento de gás natural.

Da exploração à distribuição são muitas as etapas que compõem a cadeia produtiva do gás natural, dentre elas o processamento, que gera produtos de maior valor agregado e garante a especificação técnica adequada para comercialização do gás disponibilizado para venda. Entende-se por processamento de gás natural a sequência de operações unitárias que têm por objetivo separar os componentes mais pesados do gás em uma corrente líquida, tornando o gás mais leve. A corrente líquida, normalmente formada pelo propano (C3) e outros componentes mais pesados, é conhecida como LGN (Líquido de Gás Natural). O LGN é fracionado para se obter o GLP (Gás Liquefeito de Petróleo) e a nafta leve (C5+). Estas correntes líquidas possuem um maior valor energético e, conseqüentemente, um maior valor econômico.

Uma Unidade de Processamento de Gás Natural (UPGN) visa à recuperação dos hidrocarbonetos mais pesados do gás na forma líquida, de maior valor agregado, e na especificação do gás natural processado (residual) para usos industrial, residencial e veicular. Os processos variam de um simples acerto do ponto de orvalho (*dew point*) chegando até a produção de etano líquido. Várias são as configurações que podem ser obtidas em uma UPGN. A mais simples delas consiste em produzir apenas o LGN, que é composto de propano e hidrocarbonetos mais pesados do que ele, sendo esta unidade conhecida como URGN (Unidade de Recuperação de Gás Natural).

Em termos econômicos, a escolha do melhor processo a ser utilizado em uma UPGN depende basicamente de três fatores:

- i) composição do gás;
- ii) pressão disponível; e
- iii) recuperação desejada.

No entanto, como não existem critérios rígidos que orientem a seleção, é recomendável que se faça um estudo técnico e uma análise econômica para cada tipo de processo. São quatro os principais tipos de processos para a recuperação de líquidos ou controle do ponto de orvalho do gás natural:

- Refrigeração simples;
- Expansão Joule-Thomson;
- Absorção refrigerada;
- Turbo-expansão.

O processo de turbo-expansão é o mais eficiente processo termodinâmico atualmente utilizado em unidades de processamento de gás natural. Ele possui excelente rendimento na recuperação de propano, sendo capaz de praticamente zerar o teor desse componente no gás processado. As etapas desse processo podem sofrer alguma alteração, em função de especificidades de cada projeto, porém de uma forma geral atendem aos seguintes requisitos (Vaz *et al.*, 2008):

- Compressão inicial;
- Dessulfurização;
- Desidratação;
- Regeneração;
- Pré-resfriamento;
- Expansão de gás natural;
- Desmetanização;
- Compressão de gás residual;
- Fracionamento do LGN.

A torre desmetanizadora pode ser utilizada para operar como uma desetanizadora, rejeitando etano para o gás disponibilizado para venda, como no caso da URGN em estudo.

2.2.DETEÇÃO, DIAGNÓSTICO E CORREÇÃO DE FALHAS

Durante muito tempo o termo “diagnóstico” foi invariavelmente relacionado à medicina, caracterizando o campo que trata do reconhecimento de doenças através de sintomas. O diagnóstico aplicado a sistemas tecnológicos, como uma área do conhecimento, começou a se desenvolver há cerca de 50 anos atrás. No início, os objetos de interesse de diagnóstico eram somente maquinaria e dispositivos mecânicos. Em seguida, foram acrescentados outros objetos de interesse, como dispositivos elétricos, sistemas eletrônicos, dispositivos tecnológicos complexos e mais recentemente indústrias de manufatura e de processamento, bem como sistemas de controle.

O desenvolvimento da área de diagnóstico aplicado a sistemas tecnológicos começou de forma mais consistente na década de 70, em vários lugares, com trabalhos como os de Beard (1971) e Jones (1973), que relataram a detecção de falhas em sistemas lineares baseada em observadores. Um resumo deste desenvolvimento é dado por Willsky (1976). A primeira publicação sobre a detecção e o diagnóstico de falhas em problemas relacionados à indústria de processamento foi o trabalho de Himmelblau (1978), que tratou de métodos baseados em modelos (Chiang *et al.*, 2001). Desde então diversas aplicações foram relatadas nessa área como, por exemplo, em reatores químicos, bioquímicos e de polimerização, em processos de refino de petróleo, além de processos das indústrias de aço e papel.

Durante as últimas décadas, a pesquisa em detecção e diagnóstico de falhas ganhou interesse crescente no mundo inteiro. Este desenvolvimento foi, e continua sendo, estimulado principalmente pela tendência de automação de processos e pelo crescimento da demanda por disponibilidade mais elevada e pela segurança dos sistemas de controle. Um estímulo igualmente forte vem do lado da moderna teoria de controle, que trouxe técnicas poderosas de modelagem matemática, avaliação de estados e identificação de parâmetros, que se tornaram possíveis graças ao progresso da informática moderna (Frank, 1990). Hoje em dia a teoria de detecção, diagnóstico e correção de falhas (FDCC) está transformando-se em um campo importante da teoria de controle automático. Nos primeiros vinte anos, foi a comunidade de controle que fez contribuições decisivas, enquanto nos últimos anos, a evolução tem sido marcada por um número crescente de contribuições da ciência da computação e da inteligência artificial (Palma, 2006).

Tradicionalmente as tarefas de detecção e diagnóstico estiveram ligadas à área de confiabilidade, disponibilidade e manutenibilidade (RAM, *Reliability, Availability and Maintainability*), e por esse motivo muitas vezes ainda é tratada dessa forma. No Brasil, a norma de RAM (ABNT, 1994) atribui essas tarefas à manutenção. Contudo, a tendência atual é a incorporação dessas tarefas pelo setor de automação, pois a automação das tarefas de detecção e diagnóstico tem gerado sistemas de supervisão com diagnóstico de falhas, como os sistemas de controle tolerantes a falhas.

Segundo Venkatasubramanian *et al.* (2003a), a indústria de processamento considera a automação dos sistemas de detecção e diagnóstico de falhas como o próximo marco da pesquisa e da aplicação de sistemas de controle, assim como foi a automação do controle regulatório no passado. O interesse crescente no campo foi levado em consideração e, assim, foi criado em 1991, dentro da IFAC (*International Federation of Automatic Control*, Federação Internacional de Controle Automático), um comitê de direção do SAFEPROCESS (*Symposium on Fault Detection, Supervision and Safety of Technical Processes*, Simpósio em Detecção de Falhas, Supervisão e Segurança de Processos Técnicos) que se transformou então em um comitê técnico em 1993 (Isermann e Ballé, 1997). O primeiro simpósio SAFEPROCESS foi organizado em Baden-Baden (Alemanha), em 1991, e uma segunda vez em Espoo (Finlândia), em 1994. Os simpósios seguintes ocorreram em Hull (Inglaterra), em 1997, Budapeste (Hungria), em 2000, Washington D.C. (Estados Unidos), em 2003, Pequim (China), em 2006, Barcelona (Espanha), em 2009 e, recentemente, na Cidade do México (México), em 2012.

Com o objetivo de fazer uma análise crítica das definições e terminologias utilizadas na área de detecção, diagnóstico e correção de falhas, foi realizada, em um projeto transversal a esta dissertação e a outros trabalhos de conclusão de curso, uma extensa revisão bibliográfica sobre o tema (Sartori *et al.*, 2012). A seguir é apresentada parte desse trabalho com denominações e definições, adotadas nessa dissertação, da área de pesquisa e dos objetos de estudo, além das principais tarefas de sistemas de FDDC e das técnicas mais utilizadas.

2.2.1. DENOMINAÇÕES E DEFINIÇÕES

Em processos industriais, existem muitas denominações para o sistema que objetiva assegurar o sucesso das operações planejadas através do reconhecimento de anormalidades no comportamento do processo e da assistência para a tomada de ações de correção. Para denominar este tipo de sistema, podem ser encontrados os termos “diagnóstico de falhas” (Frank *et al.*, 2000; Patton, 1993), “detecção de falhas” (Willsky, 1976) e “detecção e diagnóstico de falhas” (Gertler, 1988; Isermann, 1997; Isermann e Ballé, 1997; Venkatasubramanian *et al.*, 2003a). O último termo é o mais utilizado na literatura, inclusive em língua portuguesa (como, por exemplo, em Tinós, 1999; Fernandes, 2007; Rivera, 2007; Teixeira, 2000; Palma *et al.*, 2002), sendo também o mais abrangente para a definição dada no início do parágrafo. Porém, a detecção e o diagnóstico de falhas podem adicionalmente ser acoplados às ações de correção das falhas, formando um sistema mais abrangente, e, neste caso, a denominação mais abrangente para a área de pesquisa e, portanto, recomendada, seria “detecção, diagnóstico e correção de falhas”.

Diante das contradições e/ou superposições de definições e terminologias existentes na literatura e das inconsistências nas traduções para a língua portuguesa, foram propostas definições e traduções abrangentes, tais como:

- Condição de falha (*fault*) ou anormalidade (*abnormality*) é qualquer desvio de uma característica em relação aos seus requisitos, podendo, ou não, afetar a capacidade de desempenhar uma função requerida, ocasionando:
 - um evento de falha (*failure*); ou
 - um evento de mau funcionamento (*malfunction event*);
- Defeito (*defect*) é o término da capacidade de desempenhar a função requerida sob condições especificadas, sugerindo:
 - incapacidade total ou parada completa (evento de falha, *failure*); ou
 - incapacidade parcial ou irregularidade, intermitente ou não, no preenchimento da função (evento de mau funcionamento, *malfunction event*).

2.2.2. PRINCIPAIS TAREFAS DE SISTEMAS DE FDDC

De modo geral, os sistemas de FDDC possuem em comum as tarefas ou atividades de detecção de falhas, diagnóstico de falhas e correção de falhas. Embora o termo em inglês aqui utilizado para traduzir falha seja “*fault*”, pois é o termo genericamente referido a estas tarefas, “*fault*” aqui também deve ser entendido em um sentido mais amplo, podendo significar “*malfunction*”, “*failure*”, “*defect*”, “*breakdown*”, entre outros.

Detecção de falhas (*fault detection*) é a determinação da presença de uma falha no sistema e do tempo de detecção (Isermann e Ballé, 1997; Frank *et al.*, 2000; Venkatasubramanian *et al.*, 2003a), o que é feito a partir da observação de sintomas. Esta etapa indica, em certo tempo, que algo está errado com o sistema, que existe um comportamento indesejável ou inaceitável.

Essa operação pode ser feita através de diversas formas, desde o simples acompanhamento de alguma variável do sistema até a análise da diferença (chamada de resíduo) entre o valor medido de uma variável e o seu respectivo valor estimado por um modelo matemático (chamada de detecção de falhas com redundância analítica) ou medido por um instrumento extra que realiza uma medida equivalente (chamada de detecção de falhas com redundância física ou de *hardware*).

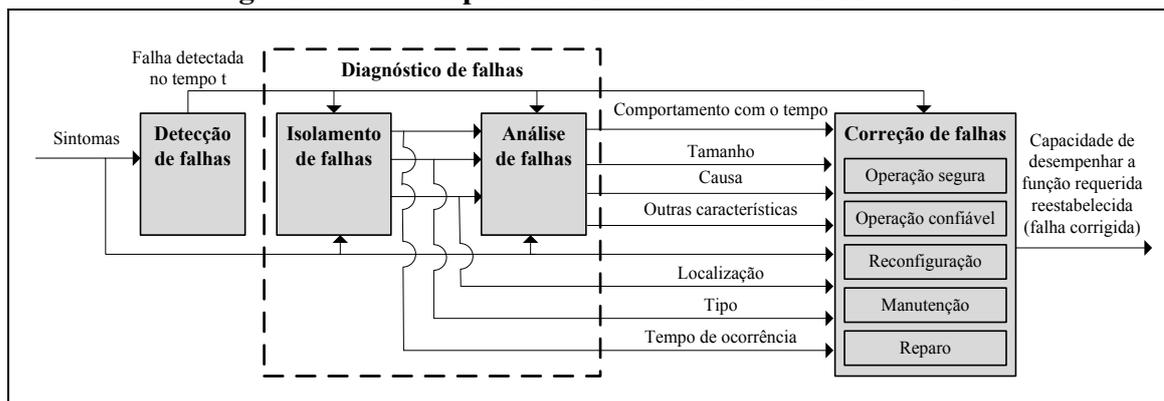
O diagnóstico de falhas (*fault diagnosis*) é a determinação das características das falhas detectadas. Essas características variam de acordo com o objetivo de cada sistema, sendo que a localização e a causa são as mais corriqueiramente abordadas na literatura. De forma abrangente, o diagnóstico de falhas pode determinar o tipo, a localização, o tamanho (magnitude), a causa, o instante e o comportamento com o tempo (Isermann e Ballé, 1997; Venkatasubramanian *et al.*, 2003a).

A etapa de correção de falhas consiste na tomada de ações apropriadas (parada, mudanças na operação, reconfiguração, manutenção ou reparo do sistema), de forma automática ou não, para restabelecer a capacidade de desempenhar a função requerida (ISO e IEC, 1993). Essa etapa é também chamada de recuperação do processo (*process recovery*) ou intervenção (*intervention*) (Chiang *et al.*, 2001). Dependendo da falha diagnosticada, as seguintes ações de correção podem ser realizadas (Isermann, 2006):

- a. Operação segura (p.e.: parada da planta);
- b. Operação confiável (p.e.: mudanças na operação);
- c. Reconfiguração (p.e.: utilizando outros sensores, atuadores ou componentes redundantes);
- d. Manutenção;
- e. Reparo.

A Figura 2.1 (Sartori *et al.*, 2012) apresenta de forma clara e didática as principais atividades de um sistema de FDDC, além da correlação existente entre elas.

Figura 2.1 - Principais atividades de sistemas de FDDC



2.3. PRINCIPAIS TÉCNICAS EM FDDC

A partir do conhecimento da complexidade do sistema em estudo e dos objetivos traçados para esse trabalho, foi realizada uma breve pesquisa para nortear a escolha da técnica a ser empregada no desenvolvimento do sistema de detecção e diagnóstico proposto.

A pesquisa compreendeu o período entre 2004 e 2010 e buscou artigos publicados em periódicos indexados na base de dados *Web of Science* (WS, 2011) que apresentassem aplicações em problemas industriais. Esta pesquisa, assim como a análise de definições e terminologias brevemente discutida, fez parte do mesmo projeto transversal anteriormente mencionado, e, desta forma, os resultados aqui apresentados são descritos também em Sartori (2012).

Foram considerados como trabalhos com aplicação em problemas industriais aqueles que contêm:

- indústrias de geração, transmissão e distribuição de energia;
- indústrias de processos químicos, bioquímicos, farmacêuticos e nucleares;
- sistemas mecânicos e indústrias de manufatura;
- captação, tratamento e distribuição de água;
- indústrias de construção naval e aeroespacial;
- indústria têxtil, indústria metalúrgica e as demais indústrias de processamento.

Não foram considerados, por exemplo, trabalhos aplicados a sistemas de telecomunicação, sistemas de condicionamento térmico, sistemas de automação predial e sistemas computacionais e de rede. Também não foram considerados trabalhos aplicados à análise de falhas estruturais (relacionadas a ensaios de materiais ou à construção civil) e falhas em equipamentos ou sistemas não industriais.

De acordo com Venkatasubramanian *et al.* (2003a), os métodos para diagnóstico de falhas podem ser classificados com base no conhecimento *a priori* utilizado. Assim, a abordagem utilizada pode envolver métodos baseados em modelos ou no histórico do processo, sendo em ambos os casos divididos em métodos quantitativos e qualitativos. O Quadro 2.1 apresenta as técnicas classificadas com base no conhecimento *a priori* utilizado, e foi construído a partir dos seguintes trabalhos: Isermann (1997), Isermann e Ballé (1997), Teixeira (2000), Venkatasubramanian *et al.* (2003a, b, c) e Blázquez e Miguel (2005).

Quadro 2.1 - Classificação das técnicas com base no conhecimento *a priori* utilizado

MODELOS		HISTÓRICO DO PROCESSO	
QUANTITATIVOS	QUALITATIVOS	QUANTITATIVOS	QUALITATIVOS
<ul style="list-style-type: none"> • Observadores de estados e de saídas • Equações e espaço de paridade • Filtro de Kalman estendido (EKF, <i>Extended Kalman Filter</i>) • Identificação e estimação de parâmetros 	<ul style="list-style-type: none"> • Árvores de falha • Simulação qualitativa (QSIM, <i>Qualitative SIMulation</i>) • Teoria qualitativa de processo (QPT, <i>Qualitative Process Theory</i>) • Grafos direcionados com sinais (SDG, <i>Signed Directed Graph</i>) 	<ul style="list-style-type: none"> • Classificadores estatísticos • Redes neurais (NN, <i>Neural Networks</i>) • Análise de componentes principais (PCA, <i>Principal Component Analysis</i>) • Método dos mínimos quadrados parciais (PLS, <i>Partial Least Squares</i>) 	<ul style="list-style-type: none"> • Sistemas especialistas (ES, <i>Expert System</i>) • Análise qualitativa de tendências (QTA, <i>Qualitative Trend Analysis</i>)

Diversas técnicas de detecção e diagnóstico de falhas foram utilizadas nos artigos encontrados, destacando-se as técnicas de base estatística e o uso crescente da inteligência artificial. Mais de 20 técnicas foram aplicadas de forma bem distribuída, o que explica o fato de aproximadamente metade de todos os artigos encontrados contemplar o conjunto das técnicas mais utilizadas, que são as seguintes, em ordem decrescente de utilização:

- redes neurais artificiais;
- lógica *fuzzy* (difusa, nebulosa);
- análise de componentes principais;
- filtro de Kalman;
- máquina de vetores de suporte (*Support Vector Machine*, SVM);
- algoritmo genético (*Genetic Algorithm*, GA);
- controle estatístico de processos (*Statistical Process Control*, SPC);
- sistemas especialistas;
- análise discriminante de Fisher;
- regressão por mínimos quadrados parciais; e
- grafos direcionados com sinais.

Dentre as técnicas citadas, destacam-se as sete primeiras, pois estas respondem por quase 90% dos artigos desse grupo, o que mostra a grande participação das técnicas classificadas como inteligência artificial entre os trabalhos mais recentes.

Algumas particularidades podem ser observadas no uso das técnicas citadas acima. Redes neuronais artificiais, por exemplo, são conhecidas por serem tolerantes a ruídos, pois são adaptativas e capazes de generalizar (Ozyurt e Kandel, 1996). Então, devido à sua capacidade de modelar sistemas complexos, reconhecer padrões e classificar informações, são largamente utilizadas em diversos sistemas e têm se mostrado capazes de obter bons resultados quando aliadas a outras técnicas. Da mesma forma, a lógica *fuzzy*, que foi desenvolvida para tratar imprecisões, ambiguidades e incertezas nas informações (Meza *et al.*, 2006), tem tido aplicação nos mais diversos sistemas, muitas vezes em conjunto com outra técnica. Tanto em um caso quanto no outro, sistemas neuro-*fuzzy* foram os mais utilizados, quando técnicas híbridas foram aplicadas (Ayoubi e Isermann, 1997).

A análise de componentes principais (PCA) envolve um procedimento matemático que transforma um número de possíveis variáveis correlacionadas em um número menor de variáveis não correlacionadas, chamadas de componentes principais. Em sistemas complexos e com muitas variáveis envolvidas, como os sistemas típicos da indústria de processos, a PCA é bastante utilizada, em alguns casos como método de referência para comparação com outras técnicas (Lee *et al.*, 2006). Já o algoritmo de aprendizagem SVM consiste em uma técnica computacional de aprendizado supervisionado para problemas de reconhecimento de padrões. Este algoritmo tem como objetivo a determinação de limites de decisão que produzam uma separação ótima entre classes, por meio da minimização dos erros (Vapnik, 1995). Em muitos casos é utilizado em combinação com outras técnicas e tem bastante aplicação em problemas de detecção de falhas em motores, equipamentos rotativos e rolamentos, bem como em sistemas de transmissão de energia elétrica. O algoritmo genético, por ser um algoritmo de otimização e busca, tem sido utilizado principalmente aliado a outras técnicas, em geral como estimador de parâmetros, como em Fei e Zhang (2009). Redes neuronais, lógica *fuzzy* e SVM são as técnicas com as quais o GA é mais utilizado de forma conjunta.

As áreas onde esses artigos se concentram são basicamente cinco, de acordo com a classificação da *Web of Science*:

- i) engenharia elétrica e eletrônica;
- ii) automação e sistemas de controle;
- iii) engenharia química;
- iv) inteligência artificial; e
- v) engenharia mecânica.

Estas áreas estão de acordo com os sistemas de aplicação mais utilizados, já que a maioria dos trabalhos é aplicada em sistemas ligados a geração, transformação e distribuição de energia elétrica (14%), equipamentos da indústria de processos (reatores, colunas, sensores e atuadores) (59%), e motores e rolamentos (21%).

Especificamente em plantas de processamento de gás natural, quase não são encontradas aplicações de sistemas FDDC. Entre os trabalhos publicados são encontradas aplicações em sistemas de distribuição de gás natural (Sun *et al.*, 2000), processos de desidratação do gás (Darwish, 2008) e na detecção de gás fora de especificação em uma rede de distribuição (Olunloyo *et al.*, 2004).

2.3.1. FDDC NA INDÚSTRIA DE PROCESSOS

A necessidade de se lidar com um grande número de dados de falha ou com a ausência de dados bem definidos, aliada ao aumento da complexidade das plantas industriais e das exigências de segurança pessoal e ambiental, tem levado à utilização de técnicas cada vez mais específicas e/ou sofisticadas. Na indústria de processo, a abordagem de inteligência artificial para a classificação das falhas tem recebido muita atenção por causa de sua facilidade de implementação, de seu desempenho na aprendizagem de sistemas não lineares, e de sua capacidade de reconhecimento e associação de padrões (Bishop, 1995; Ripley, 1996).

De acordo com a classificação de Chiang *et al.* (2001), Frank (1990) e Venkatasubramanian *et al.* (2003a), os sistemas de FDDC podem prever os estados de falha que ocorrem nos parâmetros do processo, nos componentes, nos sensores ou nos atuadores. De forma geral, os sensores são componentes-chave na detecção das falhas que causam a parada da planta, já que a informação que parte de vários sensores é utilizada pelo sistema de proteção para acionar o intertravamento da planta (Perla *et al.*, 2004). As informações que

partem dos sensores devem ser confiáveis também para serem usadas nos sistemas de controle e nos demais sistemas de FDDC (Kusiak e Song, 2009). A detecção e o diagnóstico de falhas vêm sendo explorados com sucesso para sensores em diversas aplicações industriais, como por exemplo:

- reator químico simulado (Pierri *et al.*, 2008; Li e Jeng, 2010);
- coluna de destilação simulada (Perla *et al.*, 2004; Li e Jeng, 2010);
- caldeira simulada (Qin e Li, 1999);
- tratamento de resíduo simulado (Qin e Li, 2001; Khan, 1998);
- sistema de geração de energia fóssil (Xu *et al.*, 1999);
- planta piloto para testes experimentais de algoritmos de controle (Afonso *et al.*, 1998);
- planta de energia nuclear real (Kusiak e Song, 2009);
- compressor de um sistema de refrigeração a propano (Mendonça *et al.*, 2009);
- compressor de uma URGN (Andrade, 2012; Sartori, 2012).

A capacidade das redes neuronais no reconhecimento de padrões é amplamente explorada na detecção e diagnóstico de falhas e possui revisões de seus usos em diversos processos (Venkatasubramanian *et al.*, 1990; Kramer e Leonard, 1990; Frank e Köppenseliger, 1997), sejam eles estáticos ou dinâmicos. No caso particular de sensores industriais, também se observa a utilização de redes neuronais para o desenvolvimento de sistemas de FDDC (Xu *et al.*, 1999; Perla *et al.*, 2004; Sartori, 2012).

2.4.SIMULAÇÃO DE PROCESSOS

Os conhecimentos essenciais da Engenharia Industrial de Processamento e áreas correlatas podem ser divididos em quatro grupos:

- **Ciências Básicas**, que tratam da descrição e da quantificação dos fenômenos naturais;
- **Fundamentos**, que tratam da compreensão e da representação dos fenômenos que ocorrem nos equipamentos;
- **Engenharia de Equipamentos**, que trata da concepção, do dimensionamento e da análise dos equipamentos da indústria química;
- **Engenharia de Processos**, que compreende a concepção, o dimensionamento e a análise dos processos industriais.

Os temas relacionados aos três primeiros grupos constituem a essência da engenharia industrial de processamento e áreas correlatas, logo possuem uma extensa bibliografia básica, uma sólida base teórica e são estudados desde os primórdios destas disciplinas. Por outro lado, os temas relacionados com a Engenharia de Processos diferem em essência dos demais por tratar do projeto de processos integrados. Assim, demoraram a ser abordados no ensino formal e a aparecer em livros-texto tradicionais (Perlingeiro, 2005).

A partir das primeiras publicações de trabalhos sobre avaliação econômica, otimização, efeitos da incerteza e concepção de processos químicos, a síntese e análise de processos industriais não parou mais de se desenvolver. A utilização de computadores cada vez mais robustos tornou possível a substituição progressiva das correlações empíricas simples por modelos numéricos mais rigorosos e complexos.

Estudos de processos podem ter diferentes formas de abordagem. Uma abordagem é interferir diretamente nas rotinas operacionais, promovendo implementações e/ou alterações de procedimentos até que sejam obtidas as condições ideais. Ações deste tipo requerem do profissional experiência e condução de estudos preliminares para que o desempenho do sistema não seja prejudicado pelas alterações. Outra abordagem é a utilização de modelos que representem os sistemas reais, os quais podem ser físicos, um objeto real que imita o comportamento de outro, normalmente em pequena escala, ou matemáticos, que descrevem o comportamento do sistema através de relações matemáticas com soluções analíticas ou numéricas (Garcia, 2005).

Os modelos matemáticos podem ser implementados em computadores utilizando linguagens de programação ou linguagens de simulação, permitindo assim a realização de experimentos equivalentes aos que poderiam ser realizados no processo real. A simulação permite a geração de cenários, a partir dos quais se pode orientar o processo de tomada de

decisão, realizar análises e avaliações de sistemas e propor soluções para a melhoria de desempenho. Todos estes procedimentos podem ser norteados por parâmetros técnicos e/ou econômicos.

O processamento de gás natural é considerado um processo complexo devido a diversos fatores, como alta integração entre os sistemas, processos criogênicos, e a necessidade de manter as especificações, geralmente bem restritivas, dos produtos. É economicamente mais viável, mais rápido e mais seguro realizar estudos através de simuladores de processo do que através de testes experimentais na unidade em operação. Contudo, os testes reais ainda são necessários, pois são extremamente importantes para a validação dos modelos e a verificação de novas opções de modelo. Normalmente os processos mais complexos justificavam os esforços no desenvolvimento de modelagem, simulações dinâmicas e controle (Cordeiro, 2011).

A simulação computacional está imersa em praticamente todas as áreas de atividade da Engenharia de Processo. Atualmente, o uso de simuladores de processo comerciais permite desenvolver com facilidade modelos de plantas industriais e por isso é uma prática bem sucedida em indústrias petroquímicas. Os engenheiros de processo podem trabalhar com diferentes tipos de modelos de plantas e o modelo não precisa ser totalmente fidedigno, apenas deve ser representativo o suficiente para descrever o comportamento do processo de forma satisfatória, de acordo com os objetivos de desempenho requerido para a aplicação em questão.

Para o desenvolvimento de sistemas de detecção, diagnóstico e correção de falhas, a modelagem do processo é de grande importância, principalmente quando não estão disponíveis dados históricos suficientes de estados de falhas, como acontece com plantas de pouca idade. A simulação pode prover dados de estados de falhas porque nos casos em que a falha raramente ocorre, ou mesmo nunca ocorreu, não é possível desenvolver o sistema de FDDC usando somente dados reais da planta. Além disso, o modelo também é útil para testar e validar o sistema de FDDC desenvolvido (Ruiz *et al.*, 2001). Portanto, a simulação assistida por computador é uma importante ferramenta que pode ser amplamente utilizada, não só na fase de projeto, como também durante a fase de operação.

Existem no mercado diversas opções de simuladores de processo capazes de gerar modelos de plantas extremamente completos, porém são poucos os que possuem ferramentas

para simular situações de falha, como o DYNOSIM (Invensys, 2012) e o Aspen Plus Dynamics (ASPEN, 2013). O Aspen possui como uma de suas características uma linguagem flexível para tarefas, o que permite definir esquemas de transição ou simular falhas nos equipamentos. Já o DYNOSIM possui uma ferramenta específica para simulação de falhas onde qualquer número de falhas individuais pode ser criado e, opcionalmente, guardado para recuperação e reutilização. Ao selecionar um equipamento, o DYNOSIM exibe uma janela personalizada que apresenta as características de falhas específicas pré-programadas para cada tipo de equipamento. A quase totalidade dos trabalhos que envolvem simulação de dados de falhas em plantas industriais utiliza modelos matemáticos construídos em linguagem de programação, a exemplo do MATLAB (Jiang e Yan, 2012; Lau *et al.*, 2013; Li e Zhou, 2004; Yee e Ibrahim, 2003).

O *software* EMSO é um simulador dinâmico e otimizador de processos orientado por equações, cujos modelos dos equipamentos são abertos e, portanto, permitem a adaptação de suas equações e a inserção de determinadas alterações ao longo da simulação, ao contrário dos simuladores de processos modulares. O EMSO é gratuitamente disponibilizado à Universidade Federal da Bahia (UFBA) devido à sua participação no projeto ALSOC (Ambiente Livre para Simulação, Otimização e Controle de Processos), e suas ferramentas que permitem aplicações em tempo real são um interessante atrativo para o desenvolvimento de sistemas FDDC. Entretanto, apenas um trabalho em detecção e diagnóstico de falhas, utilizando o EMSO, foi encontrado (Miyoshi, 2012). Em Liu *et al.* (2003), o gPROMS (PSE, 2013), simulador comercial que também possui as mesmas características citadas anteriormente, é utilizado para desenvolver um sistema de detecção e diagnóstico de falhas em *loop* fechado com o modelo dinâmico do processo e, portanto, capaz de detectar e diagnosticar as falhas *online* (em tempo real), porém não foi encontrado nenhum trabalho similar que abordasse a etapa de correção.

Ruiz *et al.* (2001) escrevem uma metodologia de desenvolvimento de um sistema FDDC, baseado em redes neurais e *fuzzy*, que utiliza um modelo dinâmico do processo para obtenção de dados e teste do sistema. Baseada no trabalho citado, uma metodologia generalizada para o uso de qualquer técnica de FDDC é proposta e resumida nos seguintes passos:

1. **Modelagem do processo.** Um modelo matemático pode ser feito a partir de dados experimentais usando técnicas de identificação ou através de balanços de massa e energia que descrevem a dinâmica do processo ou, ainda, a combinação de ambos. O modelo deve ser validado com dados reais da planta;
2. **Definição das falhas.** Três tipos de falhas podem ser considerados, falhas no processo, em controladores e em sensores. Falhas cuja detecção não pode ser justificada em termos de impacto econômico não devem ser consideradas;
3. **Determinação da medição.** No estágio de projeto, os pontos de medição podem ser escolhidos com base no método de diagnóstico de falha. Porém, na maioria das aplicações industriais o sistema de FDDC é desenvolvido usando os sensores disponíveis, usualmente instalados para fins de controle de processo. Frequentemente torna-se necessário incluir novos sensores;
4. **Simulação das falhas.** As falhas selecionadas são simuladas e os perfis de todas as variáveis são registrados;
5. **Desenvolvimento do sistema de FDDC.** Com as informações disponíveis o sistema de FDDC é desenvolvido utilizando uma técnica previamente selecionada;
6. **Teste do sistema desenvolvido através de simulação.** Teste do sistema de FDDC com o modelo da planta. O teste leva em conta a velocidade da detecção e do diagnóstico, além de sua precisão. Pode ser comparado com sistemas baseados em outros métodos;
7. **Implementação na planta real.** O passo final é a integração do sistema de FDDC com o *software* e o *hardware* existente na planta.

Nesta dissertação serão realizados os passos acima descritos, exceto o passo sete.

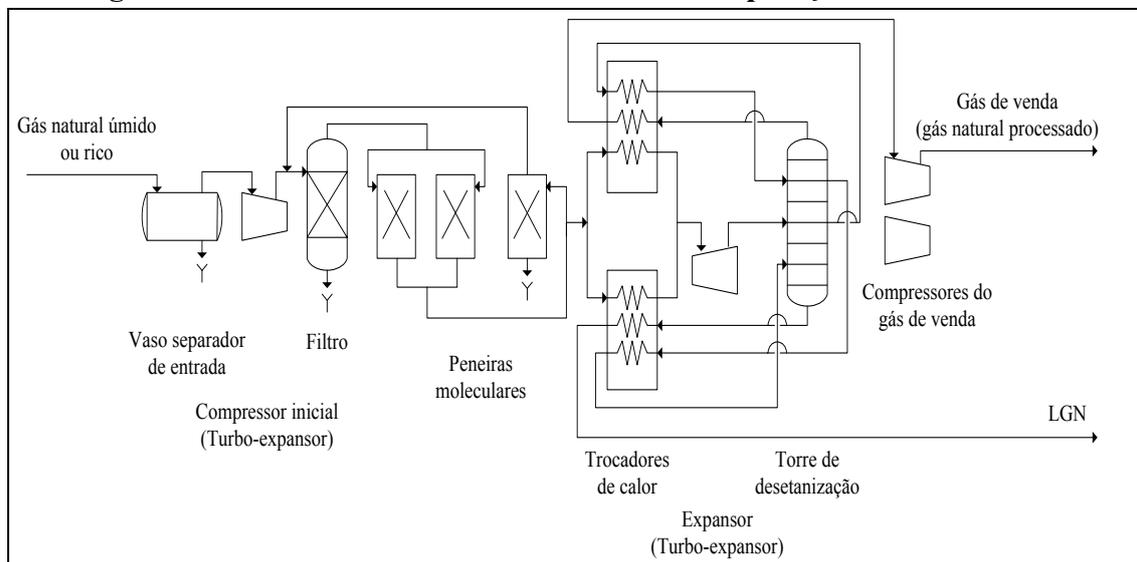
3. Modelagem e Simulação

3.1.DESCRICÃO DO PROCESSO

O sistema em estudo foi desenvolvido com base em dados reais de uma Unidade de Recuperação de Gás Natural (URGN) real que possui produção de LGN de 600 m³, capacidade de processamento de 2.75 milhões de m³ por dia (Máximo Filho, 2005) e utiliza o processo de turbo-expansão.

Como apresentado no Capítulo 2, uma URGN compreende, de forma geral, as etapas de compressão inicial, dessulfurização, desidratação, regeneração, pré-resfriamento, expansão de gás natural, desmetanização, compressão de gás residual e fracionamento do LGN. Especificamente na unidade estudada, a etapa de dessulfurização não é realizada e acontece a etapa de desetanização no lugar da desmetanização, não havendo etapa de fracionamento do LGN após a compressão de gás residual. A Figura 3.1 apresenta, de forma esquemática, um resumo das etapas do processamento do gás natural presentes na URGN.

Figura 3.1 - Processo básico da Unidade de Recuperação de Gás Natural



Fonte:Sartori (2012)

Estudos no compressor de gás de venda foram iniciados por Andrade (2012) e Sartori (2012). Sendo o LGN e o gás processado os produtos finais, percebe-se que o sistema de

Assim, a coluna desetanizadora possui duas alimentações, o gás frio que é alimentado acima do prato 1 da seção de *stripping* (esgotamento) e abaixo da seção de retificação (Alimentação 1), e o condensado oriundo do V-1000 que é alimentado no prato 30, na seção de *stripping* (Alimentação 2). Aproximadamente o mesmo fluxo volumétrico de gás que é alimentado à coluna pelo turbo-expansor é retirado pelo topo da coluna desetanizadora, enquanto todo vapor que passa pela coluna, abaixo do ponto de alimentação, é retirado no prato 1 da seção de *stripping*.

O refluxo é feito com o vapor retirado do prato 1 da seção de *stripping* e para resfriá-lo é utilizado o gás de topo. O vapor, depois de resfriado, é direcionado para o vaso acumulador de refluxo, para separação das fases líquida e gasosa. O calor introduzido na torre desetanizadora é fornecido pelas entradas laterais em conjunto com o trocador de calor (E-1100) e pelo refervedor de fundo da coluna (E-1020). O gás retirado pelo topo da coluna desetanizadora também é utilizado para resfriar o gás proveniente dos filtros de gás seco no trocador de calor gás/gás (carga do sistema) antes de ser direcionado para o sistema de compressão de gás de venda. O produto de fundo da coluna, o LGN, é resfriado antes de seguir para a estocagem, a fim de evitar a formação de vapores.

A coluna desetanizadora possui um sistema de controle regulatório projetado para assegurar que o processo se mantenha em um ponto operacional ótimo, seja capaz de eliminar perturbações e mantenha a especificação desejada dos produtos. As principais malhas de controle são de:

- nível do refervedor;
- nível do vaso acumulador de refluxo;
- temperatura de saída de vapor do refervedor;
- vazão de retirada lateral da coluna;
- vazão de refluxo e pressão na coluna.

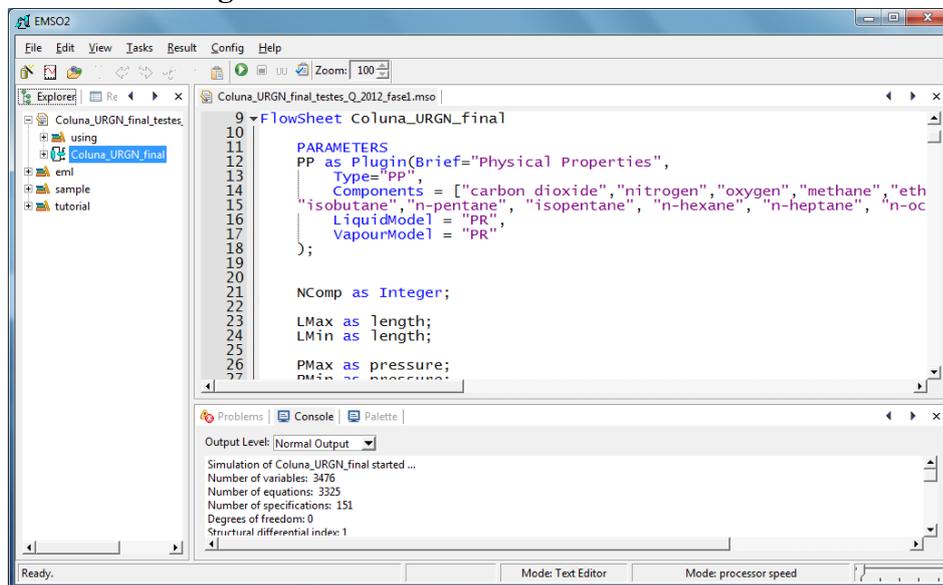
Para os objetivos desse trabalho é fundamental a representação e o entendimento do comportamento da coluna desetanizadora, porém não é necessária a representação do restante do sistema. Assim, visando à simplificação da modelagem e da simulação, não foram incluídos o turbo-expansor e os trocadores tipo placa.

3.3.MODELAGEM DA COLUNA

Com o objetivo de representar o comportamento dinâmico da coluna desetanizadora, um modelo de destilação multicomponente foi construído utilizando a linguagem de modelagem do simulador de processos EMSO (*Environment for Modeling, Simulation and Optimization*) (Amaro *et al.*, 2011).

O EMSO, cuja interface é mostrada na Figura 3.3, nasceu de um projeto acadêmico denominando Ambiente Livre para Simulação, Otimização e Controle de Processos (ALSOC), gerenciado pela Universidade Federal do Rio Grande do Sul. O projeto ALSOC é um esforço de aproximação da universidade com a indústria através da padronização e distribuição, sem custo, de especificações e ferramentas de *software* entre universidades e empresas consorciadas (UFRGS, 2012).

Figura 3.3 - Interface do simulador EMSO



O EMSO utiliza uma linguagem própria para modelagem que contém conceitos da programação orientada a objetos. Por ser uma linguagem descritiva, torna-se mais fácil construir modelos matemáticos de equipamentos e processos do que em uma linguagem de programação. Apesar de não ser um *software* de código-fonte aberto, a sua biblioteca de

modelos é aberta, permitindo ao usuário a visualização e a modificação do seu conteúdo (UFRGS, 2012).

A linguagem de modelagem do simulador EMSO é composta por três entidades principais:

- *Models*;
- *Devices*; e
- *Flowsheets*.

Na linguagem do EMSO, um *Model* consiste em uma abstração matemática de um equipamento real de uma parte de um processo. Cada modelo pode conter parâmetros, variáveis, equações, condições iniciais e até outros submodelos. *Models* podem ser baseados em outros modelos já existentes e funcionalidades extras podem ser adicionadas. Assim, os conceitos de programação modular e herança (compartilhamento de atributos e métodos pelas classes) são suportados na criação de modelos. Um *Device* é uma instância de um modelo, ou seja, a realização específica de um tipo de modelo, e representa algum dispositivo real do processo em análise. Assim, um único modelo (*Model*) pode ser utilizado para representar vários *Devices* diferentes, que possuem a mesma estrutura, porém parâmetros e especificações diferentes. *Devices* podem ser conectados entre si para formar um *Flowsheet*, que é uma abstração do processo em análise (Soares e Secchi, 2003).

Na modelagem da coluna desetanizadora foram utilizados os modelos (*Models*) de prato, condensador, refeedor, trocador de calor e vaso, disponíveis na biblioteca do EMSO, com pequenas adaptações. As propriedades físicas e termodinâmicas foram obtidas através do pacote termodinâmico VRTherm (VRTech, 2005), um *software* capaz de prever propriedades termodinâmicas e propriedades físicas de misturas complexas.

O modelo para cada prato é descrito pelas seguintes equações (Staudt *et al.*, 2007):

Pratos da coluna

Balço de massa por componente

$$\frac{dM_i}{dt} = F_{in} \cdot z_{in_i} + F_{in}^l \cdot x_{in_i} + F_{in}^v \cdot y_{in_i} - F_{out}^l \cdot x_{out_i} - F_{out}^v \cdot y_{out_i} \quad i=1,2,3,\dots,n \quad (3.1)$$

onde o subscrito *in* é usado para as correntes de entrada e o subscrito *out* para as correntes de saída, os sobrescritos *l* e *v* correspondem às fases líquida e vapor, respectivamente. As frações molares da alimentação, da fase líquida e da fase vapor são *z*, *x* e *y*, respectivamente.

Balço de energia

$$\frac{dE}{dt} = F_{in} \cdot h_{in} + F_{in}^l \cdot h_{in}^l + F_{in}^v \cdot h_{in}^v - F_{out}^l \cdot h_{out}^l - F_{out}^v \cdot h_{out}^v + Q \quad (3.2)$$

onde *h* é a entalpia molar e *Q* a taxa de calor fornecido.

Acúmulos

$$M_i = M^l \cdot x_{out_i} + M^v \cdot y_{out_i} \quad i=1,2,3,\dots,n \quad (3.3)$$

$$E = M^l \cdot h_{out}^l + M^v \cdot h_{out}^v - P_{out}^l \cdot V_{tray} \quad (3.4)$$

onde P_{out}^l é a pressão da corrente de líquido que sai do equipamento e V_{tray} é o volume total do prato.

Condição de equilíbrio termodinâmico

$$\phi_{liq} \cdot x_n = \phi_{vap} \cdot y_n^* \quad (3.5)$$

onde ϕ_{liq} e ϕ_{vap} são os coeficientes de fugacidade do líquido e do vapor, x_n é a fração molar da fase líquida para cada componente e y_n^* é a fração molar do vapor em equilíbrio termodinâmico com a fase líquida para cada componente.

Equações hidrodinâmicas

$$F_{out}^l = 1.84 \cdot lw \cdot \frac{\left(\frac{Level - (\beta \cdot hw)}{\beta}\right)^2}{v_{liq}} \quad (3.6)$$

$$F_{in}^v = \frac{Ah}{v_{vap}} \cdot \sqrt{\frac{(P_{n+1} - P_n) - \rho_{liq} \cdot g \cdot Level}{\alpha \cdot \rho_{vap}}} \quad (3.7)$$

onde, na Equação 6, F_{out}^l é a vazão de líquido deixando o prato, lw é o comprimento do vertedouro, hw é a altura do vertedouro, β é o fator de aeração, $Level$ é o nível do líquido no prato e v_{liq} é o volume molar do líquido. Na Equação 3.7, a vazão de vapor entrando no prato, F_{in}^v , é calculada pela contribuição da pressão estática ($\rho_{liq} \cdot g \cdot Level$) e pela queda de pressão no prato. A variável Ah corresponde à área total dos furos do prato, v_{vap} é o volume molar do vapor, α é o coeficiente de queda de pressão no prato seco, g é a constante gravitacional e $P_{n+1} - P_n$ é a diferença de pressão entre o prato n e aquele imediatamente superior a n ($n+1$).

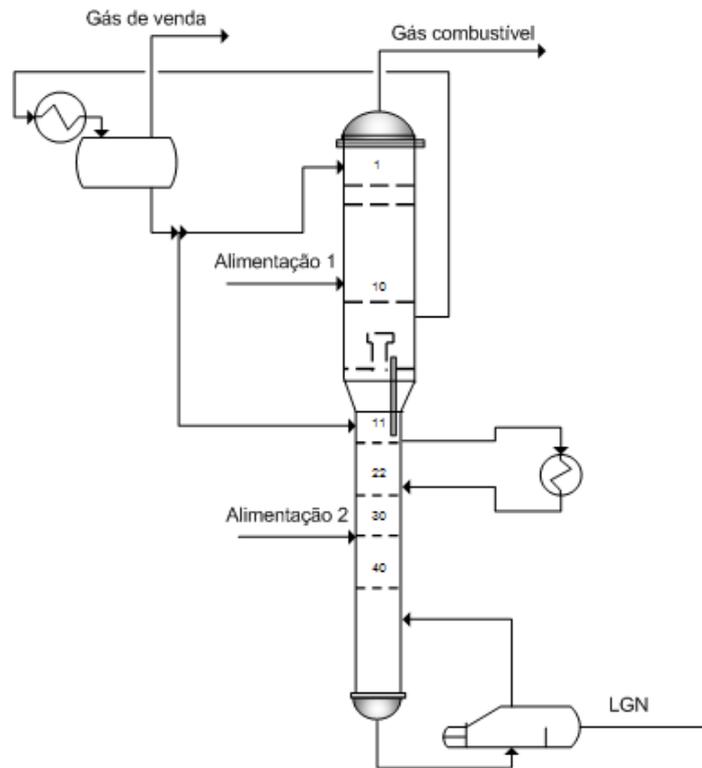
A equação de Peng-Robinson foi o modelo termodinâmico escolhido para calcular as propriedades das fases líquida e vapor, pois ela é a equação de estado mais largamente utilizada e aceita para modelar o comportamento de gás natural (Almehaideb *et al.*, 2000; Elsharkawy, 2004; Nasrifar e Bolland, 2006). A eficiência de Murphree é considerada um parâmetro conhecido do modelo:

$$E_{MV} = \frac{y_n - y_{n-1}}{y_n^* - y_{n-1}} \quad (3.8)$$

onde y_n é a fração molar do vapor no prato n e y_n^* é a fração molar do vapor em equilíbrio termodinâmico com a fase líquida.

Como as condições da carga e das correntes principais da coluna são conhecidas, condensador e trocadores de calor foram utilizados para simular as condições de temperatura fornecidas pelos trocadores tipo placa às correntes de alimentação, refluxo e reciclo. A visão esquemática da coluna simulada pode ser observada na Figura 3.4.

Figura 3.4 - Desenho esquemático da coluna modelada no EMSO



As equações, disponíveis na biblioteca do EMSO, para os equipamentos periféricos (condensador, refeedor, trocador de calor e vaso) são apresentadas em Staudt (2007) e as principais estão descritas a seguir.

Divisor de correntes: *splitter*

Vazão

$$F_{out1} = F_{in} \cdot frac \quad (3.9)$$

$$F_{out2} + F_{out1} = F_{in} \quad (3.10)$$

onde *frac* é um parâmetro fixado pelo usuário que determina qual proporção da vazão de entrada vai para a corrente *out1*.

Temperatura

$$T_{out1} = T_{in} \quad (3.11)$$

$$T_{out2} = T_{in} \quad (3.12)$$

Pressão

$$P_{out1} = P_{in} \quad (3.13)$$

$$P_{out2} = P_{in} \quad (3.14)$$

Composição

$$z_{out1_i} = z_{in_i} \quad i=1,2,3\dots n \quad (3.15)$$

$$z_{out2_i} = z_{in_i} \quad i=1,2,3\dots n \quad (3.16)$$

Entalpia

$$h_{out1} = h_{in} \text{ ou } h_{out1} = h(T_{out1}, P_{out1}, z_{out1}) \quad (3.17)$$

$$h_{out2} = h_{in} \text{ ou } h_{out1} = h(T_{out2}, P_{out2}, z_{out2}) \quad (3.18)$$

Fração vaporizada

$$v_{out1} = v_{in} \text{ ou } v_{out1} = v(T_{out1}, P_{out1}, z_{out1}) \quad (3.19)$$

$$v_{out2} = v_{in} \text{ ou } v_{out1} = v(T_{out2}, P_{out2}, z_{out2}) \quad (3.20)$$

Tanque (vaso)

Balço de massa por componente

$$\frac{dM_i}{dt} = F_{in} \cdot z_{in_i} - F_{out}^l \cdot z_{out_i} - F_{out}^v \cdot z_{out_i} \quad i=1,2,3\dots,n \quad (3.21)$$

Balço de energia

$$\frac{dE}{dt} = F_{in} \cdot h_{in} - F_{out} \cdot h_{out} + Q \quad (3.22)$$

Acúmulos

$$M_i = z_{out_i} \cdot \sum M_k \quad i=1,2,3\dots,n \quad (3.23)$$

$$E = \sum M_i \cdot h_{out} \quad (3.24)$$

Temperatura

$$T_{out}^l = T_{in} \quad (3.25)$$

$$T_{out}^v = T_{in} \quad (3.26)$$

Pressão

$$P_{out}^l = P_{in} \quad (3.27)$$

$$P_{out}^v = P_{in} \quad (3.28)$$

Composição

$$z_{out_i}^l = x_{in_i} \quad i=1,2,3\dots n \quad (3.29)$$

$$z_{out_i}^v = y_{in_i} \quad i=1,2,3\dots n \quad (3.30)$$

Fração vaporizada

$$F_{out}^v = v_{in} \cdot F_{in} \quad (3.31)$$

Entalpia

$$h_{out}^l = h(T_{out}^l, P_{out}^l, z_{out}^l) \quad (3.32)$$

$$h_{out}^v = h(T_{out}^v, P_{out}^v, z_{out}^v) \quad (3.33)$$

Refervedor dinâmico

Balanço molar por componente

$$\frac{dM_i}{dt} = F_{in} \cdot z_{in_i} + F_{in}^L \cdot x_{in_i} - F_{out}^L \cdot x_{out_i} - F_{out}^V \cdot y_{out_i} \quad i = 1, 2, \dots \quad (3.34)$$

Balanço de energia

$$\frac{dE}{dt} = F_{in} \cdot h_{in} + F_{in}^L \cdot h_{in}^L - F_{out}^L \cdot h_{out}^L - F_{out}^V \cdot h_{out}^V + Q \quad (3.35)$$

Acúmulos

$$M_i = M^L \cdot x_{out_i} + M^V \cdot y_{out_i} \quad i = 1, 2, \dots \quad (3.36)$$

$$E = M^L \cdot h_{outL} + M^V \cdot h_{outV} - P_{out}^L \cdot V_{ref} \quad (3.37)$$

Restrições das frações molares

$$\sum_i x_{out_i} = 1 \quad (3.38)$$

$$\sum_i x_{out_i} = \sum_i y_{out_i} \quad (3.39)$$

Equilíbrios químico, mecânico e térmico

$$\hat{\phi}_i^L \cdot x_{out_i} = \hat{\phi}_i^V \cdot y_{out_i} \quad i = 1, 2, \dots \quad (3.40)$$

$$P_{out}^L = P_{out}^V \quad (3.41)$$

$$T_{out}^L = T_{out}^V \quad (3.42)$$

Restrição geométrica

$$V_{ref} = M^L \cdot v^L + M^V \cdot v^V \quad (3.43)$$

Nível de líquido

$$Level = \frac{M^L \cdot v^L}{A_{cross}} \quad (3.44)$$

Condensador dinâmico ou parcial

Balço molar por componente

$$\frac{dM_i}{dt} = F_{in}^V \cdot y_{in_i} - F_{out}^L \cdot x_{out_i} - F_{out}^V \cdot y_{out_i} \quad i = 1, 2, \dots \quad (3.45)$$

Balço de energia

$$\frac{dE}{dt} = F_{in}^V \cdot h_{in}^V - F_{out}^L \cdot h_{out}^L - F_{out}^V \cdot h_{out}^V + Q \quad (3.46)$$

Acúmulos

$$M_i = M^L \cdot x_{out_i} + M^V \cdot y_{out_i} \quad i = 1, 2, \dots \quad (3.47)$$

$$E = M^L \cdot h_{out}^L + M^V \cdot h_{out}^V - P_{out}^L \cdot V_{cond} \quad (3.48)$$

Restrições das frações molares

$$\sum_i x_{out_i} = 1 \quad (3.49)$$

$$\sum_i x_{out_i} = \sum_i y_{out_i} \quad (3.50)$$

Equilíbrios químico, mecânico e térmico

$$\hat{\phi}_i^L \cdot x_{out_i} = \hat{\phi}_i^V \cdot y_{out_i} \quad i = 1, 2, \dots \quad (3.51)$$

$$P_{out}^L = P_{out}^V \quad (3.52)$$

$$T_{out}^L = T_{out}^V \quad (3.53)$$

Restrição geométrica

$$V_{cond} = M^L \cdot v^L + M^V \cdot v^V \quad (3.53)$$

Nível de líquido

$$Level = \frac{M^L \cdot v^L}{A_{cross}} \quad (3.54)$$

As principais especificações da coluna desetanizadora estão resumidas na Tabela 3.1 e estão de acordo com os dados da coluna real.

Tabela 3.1 - Especificações para estado estacionário da coluna desetanizadora

Composição molar no topo (etano)	0.0949
Composição molar no fundo (propano)	0.4917
Vazão da alimentação 1	4024.53 kmol/h
Vazão da alimentação 2	314.37 kmol/h
Vazão no topo	3965.69 kmol/h
Vazão no fundo	234.46 kmol/h
Pressão da alimentação 1	17.4 atm
Pressão da alimentação 2	17.5 atm
Temperatura da alimentação 1	198 K (-75 °C)
Temperatura da alimentação 2	308 K (35 °C)
Estágios da seção de retificação	10
Estágios da seção de esgotamento	30
Diâmetro da seção de retificação	1.8 m
Diâmetro da seção de esgotamento	1.0 m
Taxa de calor para o refeedor	900 kW

A carga da coluna é composta por duas correntes de composição e condições distintas (Alimentação 1 e Alimentação 2) provenientes do vaso separador (F-1040) e do turbo-expansor (EX-1000), como descrito anteriormente. A Tabela 3.2 apresenta a composição molar de cada alimentação da simulação, cuja carga foi considerada de 100%.

Tabela 3.2 - Composição molar da carga

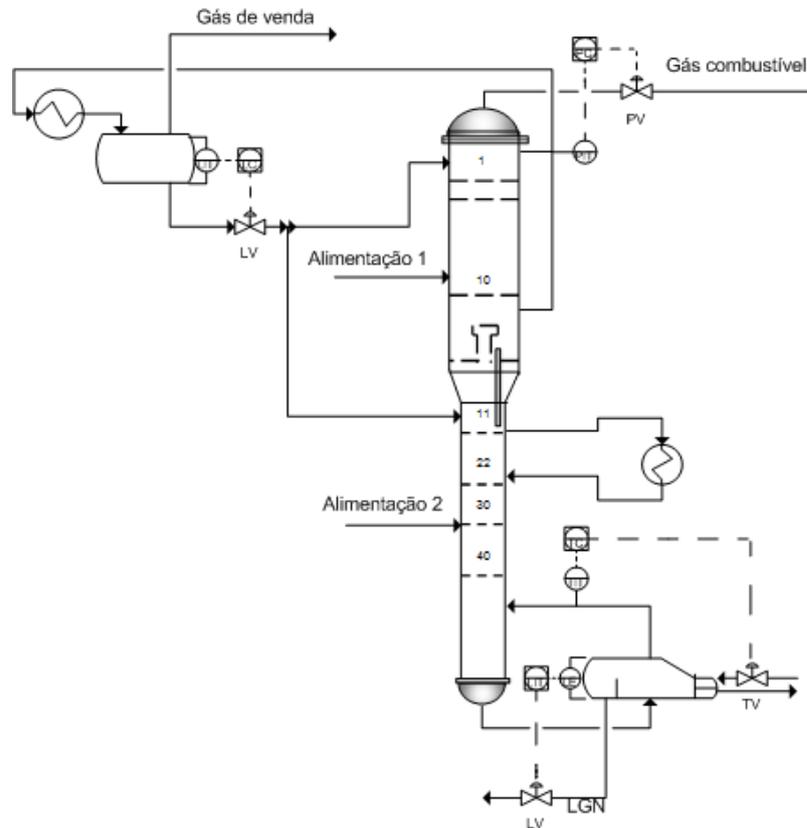
Componentes	Alimentação 1	Alimentação 2
Dióxido de carbono	0.00993	0.01095
Nitrogênio	0.00853	0.00108
Oxigênio	0.00011	0.00003
Metano	0.87624	0.36321
Etano	0.08220	0.20257
Propano	0.01790	0.16088
n-Butano	0.00188	0.06024
isoButano	0.00221	0.04878
n-Pentano	0.00039	0.04162
isoPentano	0.00047	0.03629
n-Hexano	0.00013	0.04498
n-Pentano	0.00003	0.02796
n-Octano	0.00000	0.00141

Para o controle da coluna foram inseridas no modelo as três principais malhas de controle *feedback* existentes no sistema real. Como, originalmente, a pressão operacional do sistema de desetanização é mantida pelo turbo-expansor conjuntamente com o compressor de gás de venda, foi necessário inserir uma malha de controle de pressão da coluna para substituir esse conjunto.

Modelos de controladores PID (Proporcional-Integral-Derivativo) disponíveis na biblioteca do EMSO foram utilizados e suas entradas e saídas foram convertidas em sinais normalizados (0-1). A variável controlada é convertida em um sinal normalizado, antes de entrar no controlador, baseado no *range* do transmissor. O sinal que varia entre 0 e 1 é a evidência observável da variação na variável física. De forma similar, o sinal de saída do controlador (que também varia de 0 a 1) é convertido em variável física pela válvula de controle e influencia o processo.

As malhas de controle implementadas visam manter a estabilidade da coluna e a especificação dos produtos, através do controle da pressão no topo da coluna, do nível do refeedor e do nível vaso de topo, além da temperatura no refeedor. Os pares PV-MV (*Process Variable-Manipulated Variable*; variável de processo-variável manipulada) das malhas de controle presentes na simulação são mostrados no Quadro 3.1 e na Figura 3.5.

Figura 3.5 - Desenho esquemático das malhas de controle implementadas



Quadro 3.1 - Pares PV-MV das malhas de controle

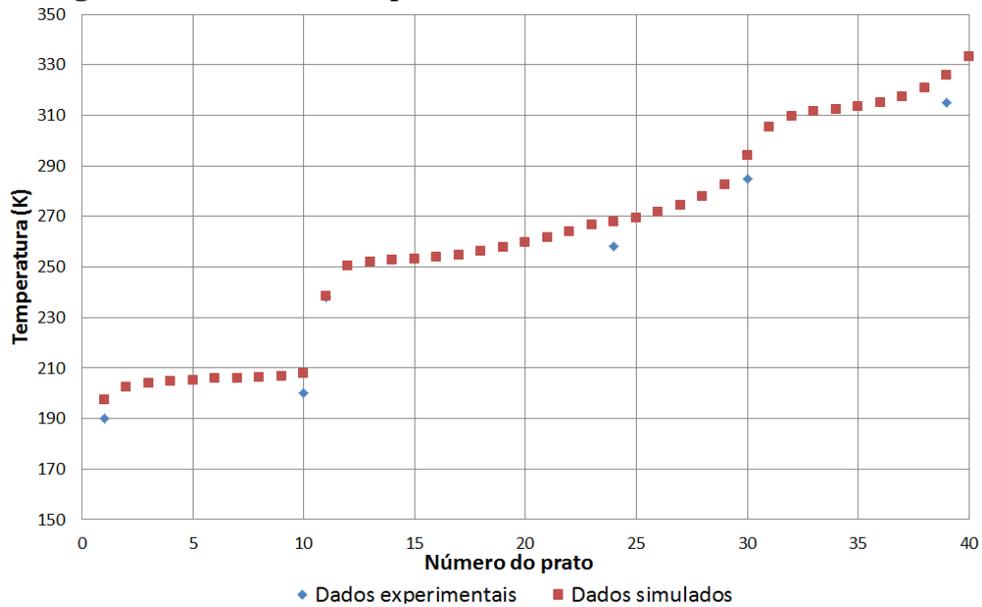
PV	MV
Temperatura da corrente de retorno do refeedor para a coluna	Taxa de calor para o refeedor
Nível do refeedor	Vazão de saída de LGN
Nível do vaso de topo da coluna	Vazão do refluxo da coluna
Pressão no topo da coluna	Vazão de saída do gás de topo

O processo de destilação é altamente não linear e a modelagem deste tipo de processo leva a sistemas mistos de equações algébricas e equações diferenciais, conhecidos como sistemas de equações algébrico-diferenciais (EAD). Para a resolução matemática dos modelos, estão disponíveis no EMSO algumas categorias de *solvers* (códigos computacionais para a resolução numérica de equações). Para a simulação da coluna foi utilizado o *solver sundials* para sistemas não-lineares (NLA) e o *dassl* para sistemas algébrico-diferenciais (EAD). Os *solvers* do EMSO são elementos independentes que são carregados dinamicamente no momento da solução. Em outras palavras, os *solvers* não são embutidos no simulador (com exceção dos sistemas lineares que são embutidos). Isto é possível através da utilização das bibliotecas de carregamento dinâmico, no Windows (arquivos tipo DLL) ou dos objetos compartilhados (arquivos SO) no Linux (Soares e Secchi, 2003).

3.4.RESULTADOS

Depois de simular o sistema por grande período de tempo (> 12 h), o estado estacionário foi alcançado e um arquivo de inicialização foi salvo para novas simulações. Dados disponíveis dos sensores de temperatura existentes ao longo da coluna foram utilizados para comparar o perfil de temperatura da coluna real com o perfil encontrado no estado estacionário da coluna simulada. Como pode ser observado na Figura 3.6, o perfil de temperatura alcançado pelo estado estacionário da coluna acompanha de forma satisfatória (desvio $\leq 3\%$) os dados experimentais. Mudanças bruscas de temperatura nos pratos 10 e 30, causadas pelas duas alimentações da coluna, podem ser observadas.

Figura 3.6 - Perfil de temperatura da coluna: valores simulado e real



Para a realização dos testes dinâmicos foram inseridas perturbações de vazão e temperatura em ambas as alimentações a fim de determinar o efeito nas condições da coluna. Perturbações na Alimentação 2 mostraram-se irrelevantes, resultado que era esperado, considerando que a vazão dessa alimentação é muito menor do que a da Alimentação 1. Assim, os testes dinâmicos foram realizados a partir de perturbações tipo degrau na corrente de Alimentação 1, pois se constatou ser essa a principal fonte de distúrbios do sistema. Duas perturbações em degrau foram introduzidas ao longo de uma mesma simulação, a primeira em $t=1000$ s e a segunda em $t = 2500$ s.

As Tabela 3.3 e Tabela 3.4 apresentam as mudanças inseridas na temperatura e na vazão da Alimentação 1 ao longo da simulação. A Figura 3.7 mostra o comportamento da temperatura do LGN e do gás de topo da coluna enquanto ocorrem as perturbações na temperatura da Alimentação 1. Na

Figura 3.8 são mostradas as respostas da vazão de LGN e da taxa de calor fornecida ao refervedor frente à perturbação degrau na Alimentação 1.

Tabela 3.3 - Simulação 1: perturbação em degrau na temperatura da Alimentação 1

Degrau (K)	Temperatura inicial (K)	Temperatura final (K)
+5	198	203
-5	203	198

Tabela 3.4 - Simulação 2: perturbação em degrau na vazão da Alimentação 1

Degrau (%)	Vazão (kmol/h)	Vazão (kmol/h)
+10	4024.53	4426.98
-10	4426.98	4024.53

Figura 3.7 - Simulação 1: Temperatura do LGN (a) e temperatura do gás de topo (b)

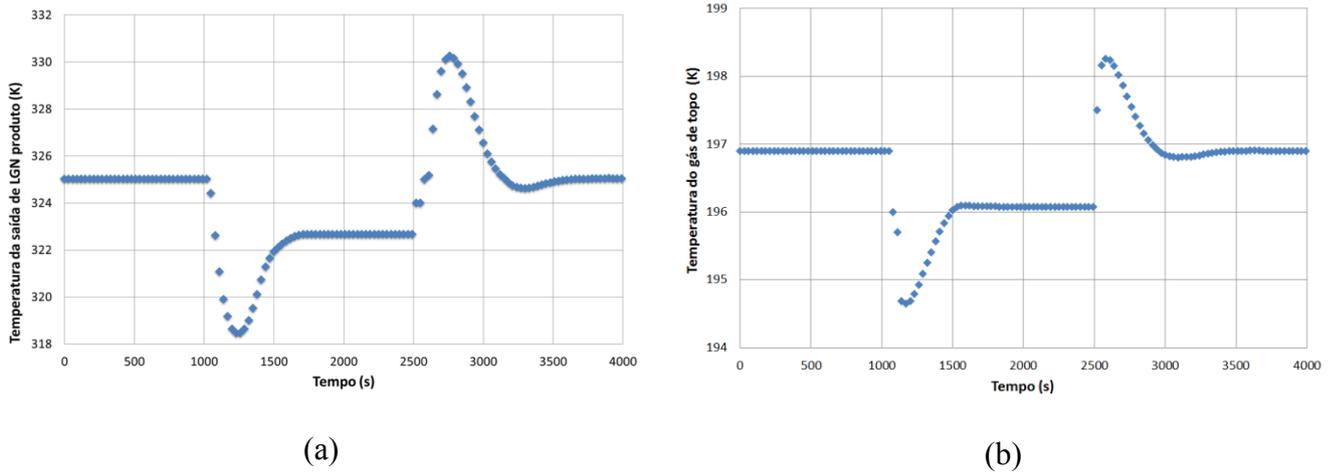
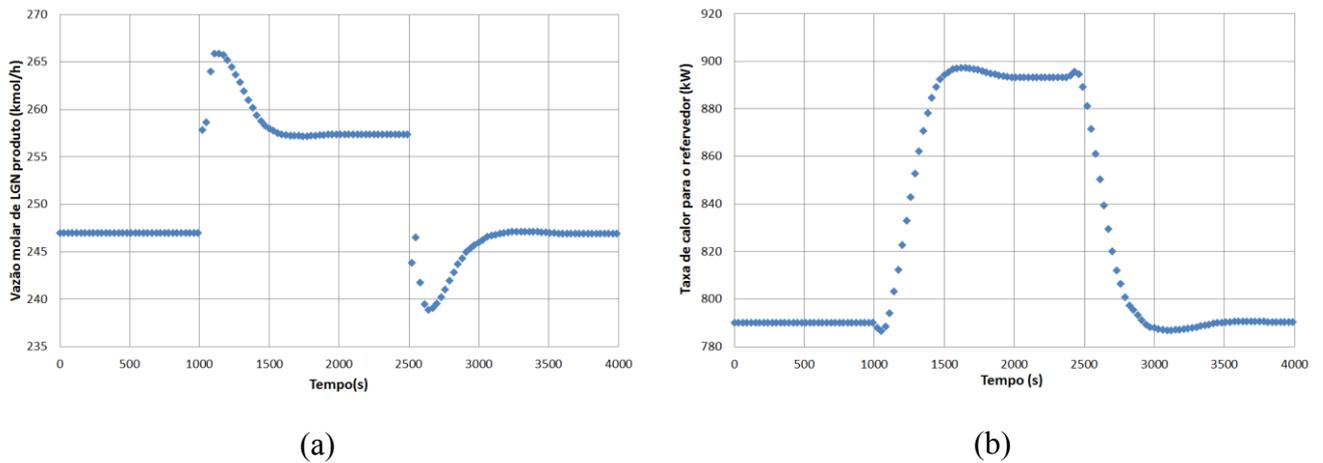


Figura 3.8 - Simulação 2: Vazão molar de LGN produto (a) e taxa de calor para o refeedor (b)



Nota-se que as perturbações na temperatura alteram levemente a temperatura do gás de saída do topo da coluna, enquanto a temperatura do produto de fundo sofre influência mais significativa. No caso de perturbações na vazão dessa alimentação, a vazão do produto de fundo da coluna é alterada, como esperado, e a taxa de calor fornecida ao refeedor reflete a necessidade de mais, ou menos, energia para manter controlada a temperatura no refeedor.

A coluna desetanizadora da URGN é uma coluna multicomponente, complexa e com perfil de temperatura íngreme. Apesar das simplificações na modelagem, os resultados do estado estacionário são compatíveis com os dados da planta e a dinâmica do processo está bem representada, de acordo com o conhecimento de especialistas (engenheiros e operadores) da Unidade. Isso demonstra que o modelo desenvolvido representa de forma satisfatória o comportamento do processo, sendo válido para os objetivos desse trabalho.

4. Construção e Integração do Sistema de FDDC

Colunas de destilação são largamente estudadas na literatura devido a sua popularidade e a sua importância dentro da indústria de processamento. Casos de falhas e mau funcionamento em colunas de destilação estão bem relatados e, apesar dos avanços na tecnologia, o ritmo de falhas em colunas de destilação está em ascensão e acelerando (Kister, 2003). Apesar de muitas plantas serem equipadas com sistemas de controle de processo automático, ações executadas por computador ainda são limitadas e altamente dependentes de operadores humanos (Behbahani *et al.*, 2009).

De acordo com Elnemr e Elewa (1996), condições de falha em colunas de destilação podem ser caracterizadas como:

- (a) *Process load* (cargas, distúrbios ou perturbações no processo), que consiste em distúrbios nas vazões de alimentação, no produto de topo, no produto de fundo e ainda em mudanças de composição da carga;
- (b) Distúrbios nas condições de fornecimento de energia, como mudanças na entrada de calor para o refeedor e mudanças na saída de calor do condensador;
- (c) Equipamentos com superfície incrustada.

4.1. SELEÇÃO DAS FALHAS

Nas publicações da área de detecção e diagnóstico de falhas, os tipos de falhas mais encontrados em colunas de destilação são:

- aumento ou diminuição da vazão de vapor para o refeedor por falha do sensor de temperatura (Brydon, 1997; Tian, 2011; Elnemr, 1996; Sharma, 2004);
- alteração na composição da carga (Brydon, 1997; Tian, 2011; Elnemr, 1996; Akhlaghi, 2008; Sharma, 2004); e
- falha no transmissor da malha de nível do vaso de topo (Brydon, 1997).

Com base nisso, foram selecionadas para simulação estas falhas, bem como algumas variantes que estavam de acordo com informações do HAZOP (*hazard and operability study*) da coluna.

A análise HAZOP é um exame estruturado e sistemático de um processo ou operação, em projeto ou existente, a fim de identificar e avaliar os problemas que possam representar riscos para o pessoal ou equipamento, ou impedir seu funcionamento eficiente. A análise HAZOP é mais amplamente utilizada e reconhecida na indústria de processos químicos e, geralmente, é realizada por uma equipe de especialistas com conhecimento especializado e experiência na concepção, operação e manutenção da planta. A imaginação dessa equipe é usada para perturbar um modelo do processo a ser estudado, por meio de um processo metódico para identificar acidentes potenciais. A análise HAZOP é útil para construir a base de conhecimento profundo (KB, *knowledge base*) da planta que contém o conhecimento dos operadores e engenheiros sobre o processo, e permite a formulação de algoritmos de inteligência artificial (Ruiz *et al.*, 2001).

No total, seis falhas foram selecionadas para simulação, e estão listadas no Quadro 4.1.

Quadro 4.1- Falhas selecionadas para simulação

FALHA	CONSEQUÊNCIA IMEDIATA
Falha no sensor da malha de controle de temperatura do refeededor	Aumento ou diminuição da vazão de vapor para o refeededor
Falha no transmissor de nível do vaso de topo	Aumento ou diminuição descontrolada do nível do vaso de topo
Falha no transmissor de nível do refeededor	Aumento ou diminuição descontrolada do nível do refeededor
Falha na válvula de refluxo	Transbordamento ou secagem do vaso de topo com provável “fuga” de líquido para a saída de gás ou aumento abrupto do refluxo para a coluna
Falha na válvula de saída líquida do refeededor	Transbordamento ou secagem do refeededor com possível ida de gás para o estoque de C3+ ou provável inundação da coluna
Alteração da composição da alimentação	Perda de especificação dos produtos

4.2.SIMULAÇÃO DAS FALHAS

O EMSO não possui nenhum módulo de simulação de falhas, nem foi projetado para englobar esse tipo de problema. Porém, por possuir sua biblioteca de modelos aberta, é possível modificar equações e variáveis a fim de inserir falhas ao longo da simulação.

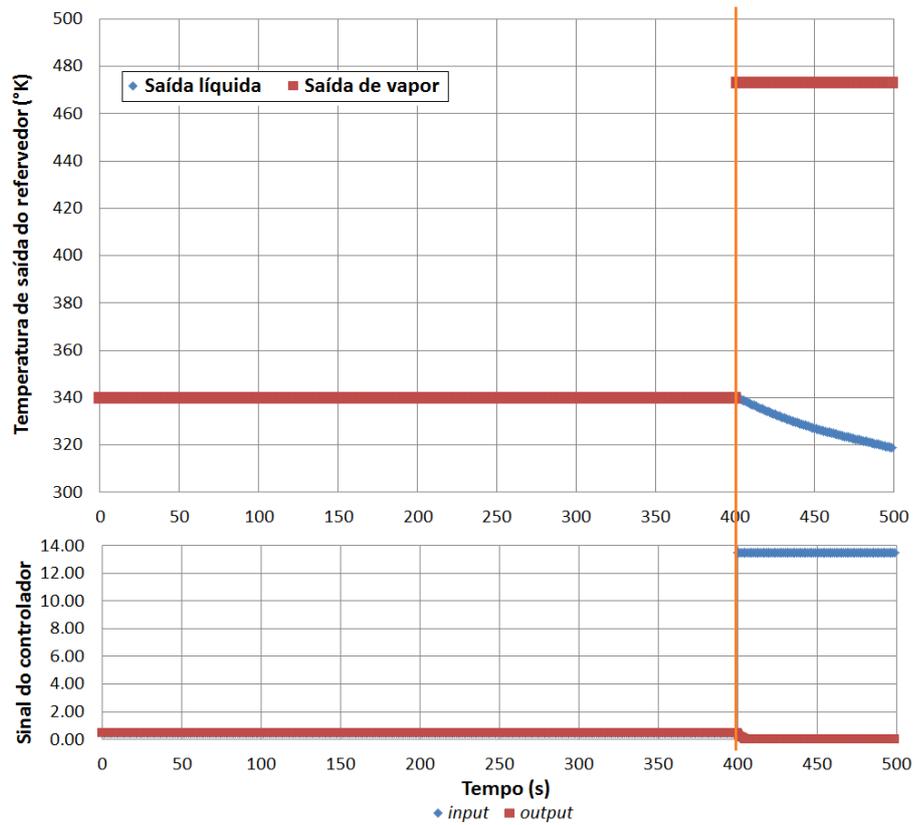
As seis falhas previamente selecionadas foram testadas, e cinco delas foram simuladas com êxito. A falha relativa à mudança de composição da carga foi a única que não pôde ser simulada, pois no momento que a falha ocorre o modelo deixa de convergir. Segundo os desenvolvedores do *software*, ao se alterar a composição da carga durante uma simulação, as propriedades físicas e termodinâmicas são recalculadas no VRTherm e, conseqüentemente, uma nova condição inicial é gerada pelo programa. O *solver* é reinicializado e as novas condições podem não mais satisfazer o sistema. Como não é objetivo deste trabalho, não foram investigadas outras possíveis causas.

Falhas em transmissores foram caracterizadas pelo congelamento do sinal de entrada do controlador em um determinado valor. No caso das válvulas, a falha ocorre por emperramento da mesma, ou seja, a válvula não responde ao sinal enviado pelo controlador. No sensor a falha mais grave é o rompimento repentino, indicado pela mudança brusca do valor medido em direção ao fundo de escala ou ao início desta.

O comportamento das variáveis diretamente influenciadas pela ocorrência das falhas pode ser observado nas Figuras 4.1 a 4.5. A reta vertical laranja indica o início do evento de falha, enquanto que a reta horizontal vermelha (Figuras 4.2 a 4.5) indica o limite superior do nível do vaso de topo ou refeedor. Como todas as falhas envolvem malhas de controle, os sinais de entrada (*input*) e saída (*output*) do controlador também são apresentados. As simulações partem do estado estacionário com todas as malhas de controle fechadas.

Na simulação de falha do sensor de temperatura (Figura 4.1), a mudança brusca da indicação de temperatura em direção ao fim de escala caracteriza o rompimento do sensor. O sinal de entrada do controlador muda bruscamente e sua saída responde de imediato, indicando o fechamento da válvula (*output* = 0) de fornecimento de calor. A interrupção do fornecimento de calor para o refeedor provoca a queda da temperatura, como pode ser observado pela indicação de temperatura da saída líquida do refeedor.

Figura 4.1 - Simulação de falha no sensor de temperatura da saída líquida do refervedor



Para simular a falha no transmissor de nível, o sinal de entrada do controlador é congelado em um valor inferior ou superior ao do estacionário (0.5), levando o sinal de saída a mudar. No caso das Figura 4.2 e Figura 4.3 e, a entrada do controlador congelada em valores ligeiramente menores (0.495 e 0.490, respectivamente) provoca uma queda progressiva no sinal de saída do controlador e um consequente aumento do nível até o transbordamento do vaso.

Figura 4.2 - Simulação de falha no transmissor de nível do vaso de topo

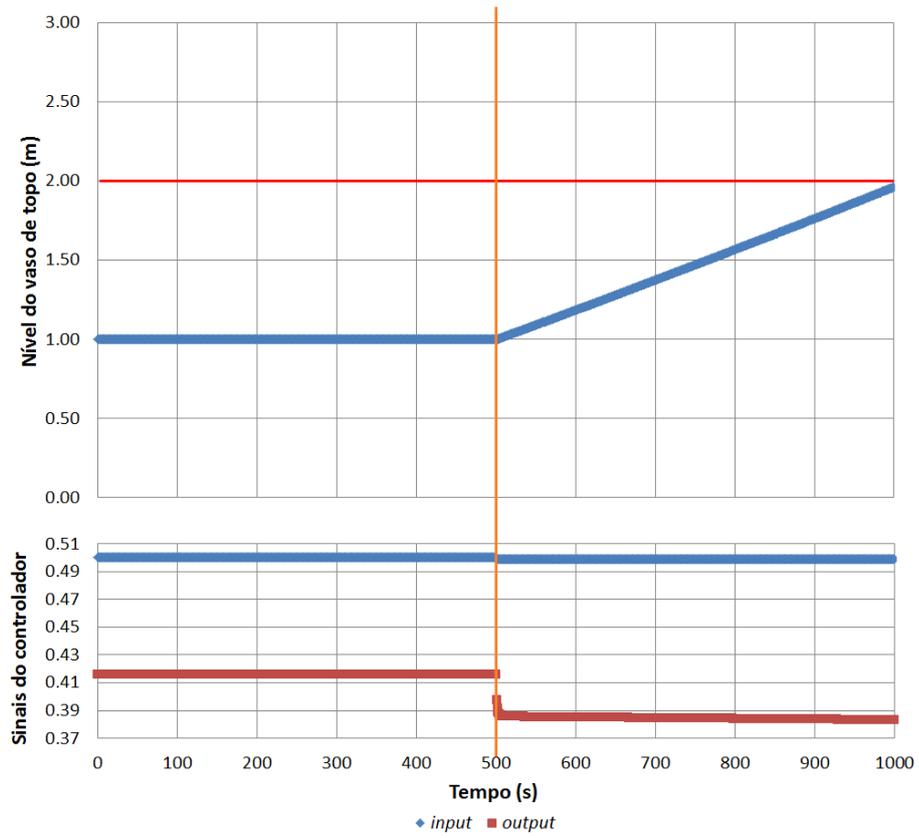
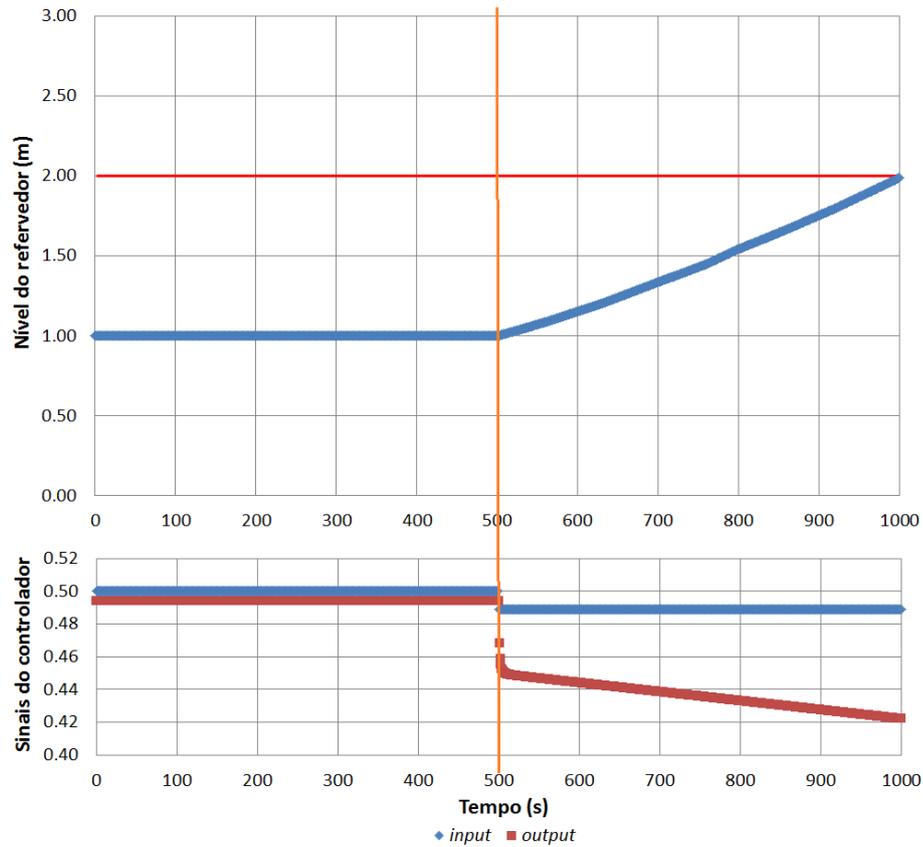


Figura 4.3 - Simulação de falha no transmissor de nível do refervedor



De forma semelhante à falha no transmissor, as falhas nas válvulas foram inseridas através da fixação de um valor para a abertura da válvula, independente do sinal que ela receba do controlador. Assim, o nível tende a aumentar ou diminuir, a depender da posição da válvula em relação ao estado estacionário. Na Figura 4.4 e na Figura 4.5 o sinal de entrada do controlador indica o aumento do nível, enquanto o sinal de saída indica a tentativa de abertura da válvula. Em todos os casos, após a ocorrência da falha, rapidamente uma situação limite é alcançada (transbordamento/secagem do vaso ou do refervedor, acionamento do sistema de intertravamento de segurança por limites de temperatura) e, portanto, a simulação é interrompida.

Figura 4.4 - Simulação de falha na válvula de refluxo da coluna

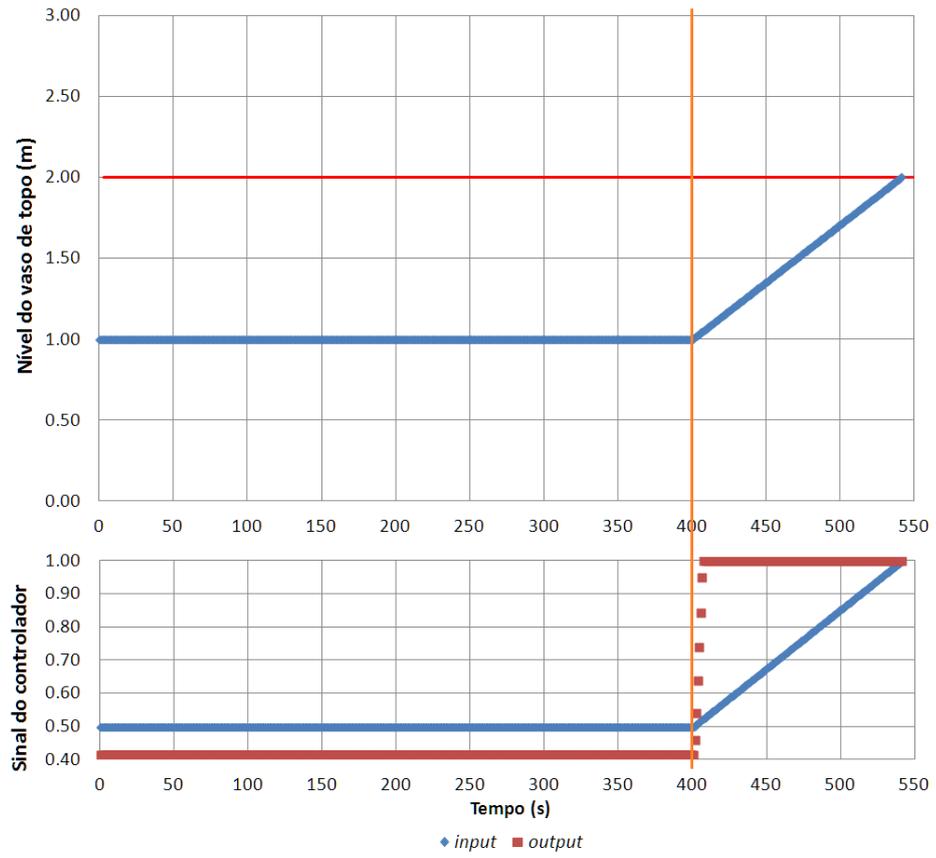
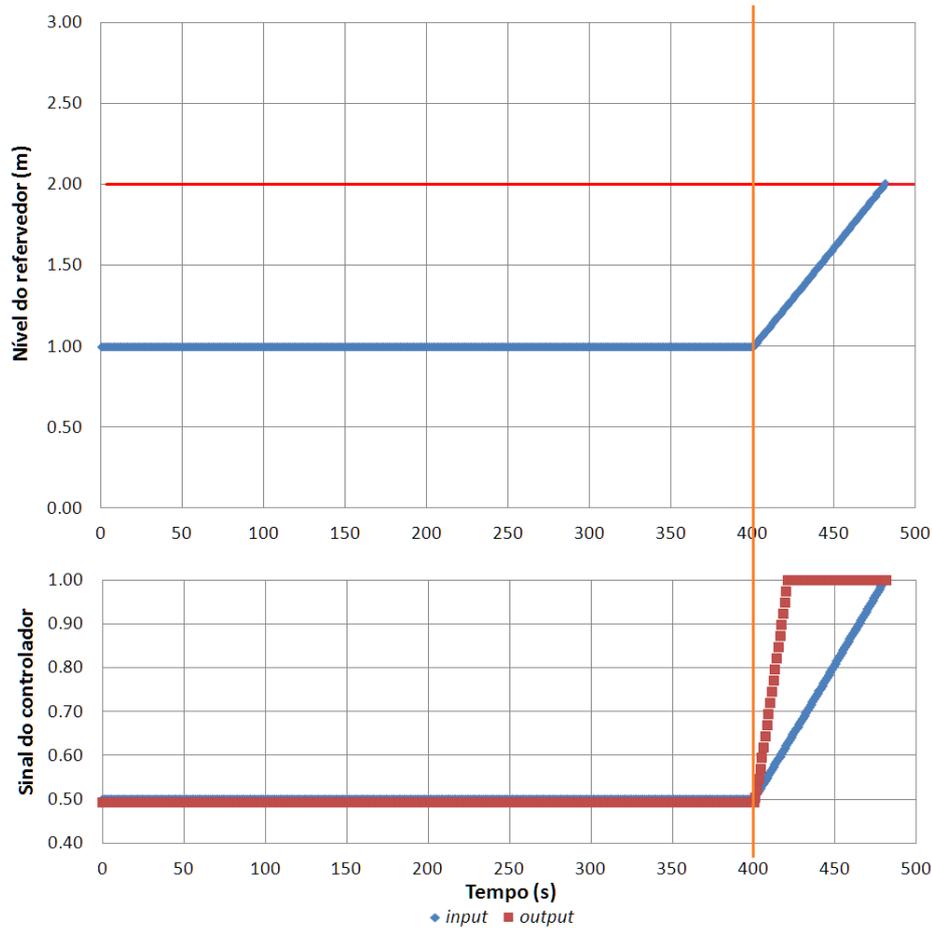


Figura 4.5 - Simulação de falha na válvula de saída do refervedor



Variações das simulações apresentadas foram realizadas diversas vezes, tendo sido verificado que, de modo geral, é possível simular no EMSO situações que envolvem falhas nos elementos do sistema de controle do processo modelado.

4.3.DETECCÃO, DIAGNÓSTICO E CORREÇÃO DAS FALHAS

Uma coluna de destilação opera em conformidade com as severas especificações de pureza do destilado, independente da qualidade do produto bruto. Devido às constantes de tempo muito longas envolvidas na operação deste tipo de processo, a detecção precoce de falhas é um problema importante: uma falha que não é detectada logo após o seu início pode resultar em desperdício de dezenas de horas de operação (Ploix e Dreyfus, 1997). Quando a falha ocorre, as configurações da coluna são alteradas. Para uma resposta satisfatória da

coluna, a peça defeituosa deve ser detectada e reparada. Assim, o problema de detecção, diagnóstico e correção de falha deve ser dividido em quatro partes (Elnemr e Elewa, 1996):

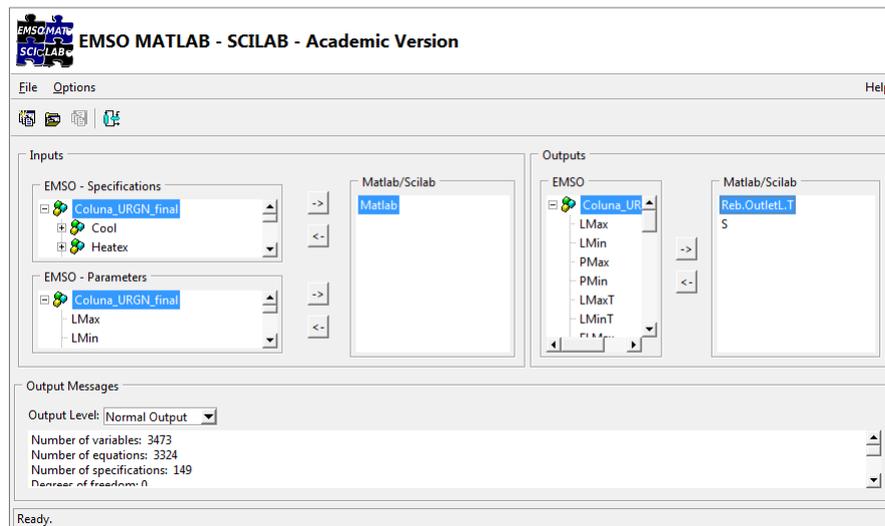
- i) o monitoramento das variáveis de acompanhamento da coluna para detectar a falha;
- ii) envio das variáveis problemáticas para o sistema de FDDC;
- iii) diagnóstico da causa da falha;
- iv) a ação de correção a ser tomada.

Como estudo de caso foi selecionada uma das falhas simuladas anteriormente para a implementação de um sistema de FDDC capaz de funcionar *online*, ou seja, em paralelo com a simulação. Como na maioria dos trabalhos com aplicação real (Palma *et al.*, 2002), o sistema a ser desenvolvido só abordará a parte de isolamento das falhas (*Fault Detection and Isolation*, FDI) da etapa de diagnóstico. O sistema irá detectar a existência da falha e o seu tipo, não sendo realizados outros detalhamentos que competem à etapa de análise da falha. Conforme comumente encontrado, as tarefas de detecção e diagnóstico serão realizadas pelo sistema em uma etapa única, ao invés de duas etapas distintas (Raich e Çinar, 1996). A etapa de correção é realizada de forma automática, em uma etapa seguinte, onde é realizada a reconfiguração da malha de controle afetada pela falha em estudo, medida esta listada por Isermann (2006) como uma dentre as possíveis ações de correção. Assim, com a etapa de correção é possível perceber como todo o sistema reage ao ser introduzida uma falha e uma ação de correção em sequência.

A ferramenta que permite a comunicação entre o modelo do processo e o sistema FDDC é a interface de comunicação EMSO/MATLAB desenvolvida pela VRTech para o projeto ALSOC. O EMSO tem uma vasta biblioteca de equipamentos de processos químicos e o principal objetivo dessa integração é a utilização desses modelos integrados com MATLAB, a fim de utilizar suas bibliotecas de controle e outros algoritmos relacionados. Basicamente, o EMSO é integrado ao MATLAB através de um bloco *S-function* do Simulink (MathWorks, 2013b). Esse bloco é configurado através da interface de configuração gráfica do usuário (GUI, *Graphical User Interface*), que constrói um arquivo texto (com extensão .ems) que será carregado pelo bloco Simulink (Figura 4.6). Na GUI, são listadas as variáveis do *Flowsheet*

para seleção das entradas e saídas do bloco de comunicação (Soares, 2007). Assim, é possível enviar uma ou mais variáveis do EMSO para o Simulink e este pode devolver outra variável (ou a mesma) à simulação do EMSO.

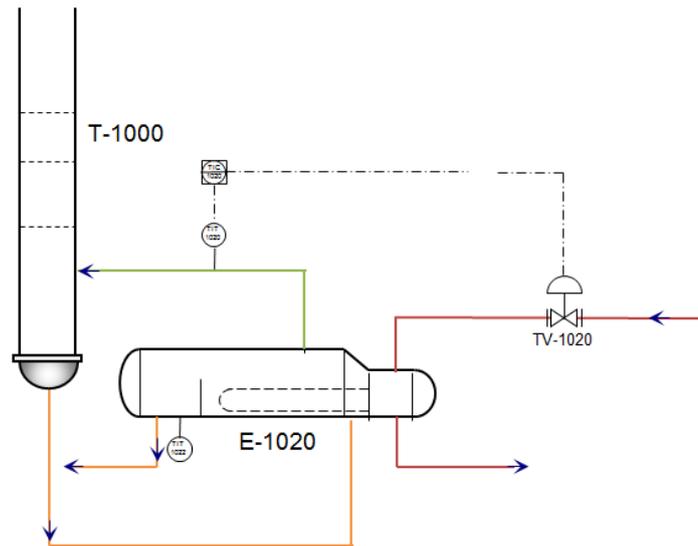
Figura 4.6 - Configuração gráfica do usuário (GUI)



4.3.1. ESTRUTURA DO SISTEMA E PADRÕES DE FALHA

A falha escolhida para este estudo de caso pertence à malha de controle de temperatura do refeedor (Figura 4.7), cuja falha no sensor de temperatura leva ao aumento/redução do fluxo de calor para o refeedor. A estratégia de detecção foi baseada na redundância de sensores disponíveis na planta. Além do sensor de temperatura do vapor que sai do refeedor em direção à coluna (malha de temperatura), existe um sensor de temperatura na saída líquida do refeedor, que não pertence a nenhuma malha de controle.

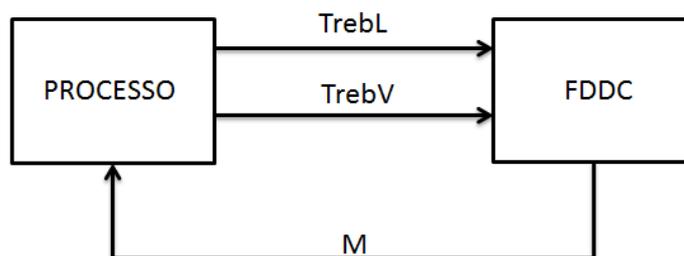
Figura 4.7 - Destaque da malha de controle de temperatura do refervedor



Assim, a estratégia para o desenvolvimento do sistema de detecção de falhas foi elaborar um sistema capaz de comparar as medidas de temperatura no refervedor e perceber a mudança, caso o comportamento saísse do padrão. O *setpoint* da malha de controle de temperatura do refervedor é 67 °C e o sensor possui faixa de medida (*range*) de 0 °C a 200 °C.

O sistema de FDDC deve receber como entrada as medições de temperatura no refervedor (“TrebL”, temperatura da saída líquida do refervedor; e “TrebV”, temperatura da saída de vapor do refervedor) e enviar para o EMSO um *flag* (sinalizador M) indicando o *status* (situação) do processo (Figura 4.8). Ao receber indicação de falha do sensor, a malha de controle em questão terá sua PV (*Process Variable*) alterada para o valor da medição redundante. Ao ser sanado o problema no sensor, o sistema deve perceber o padrão de comportamento normal, alterar novamente o *flag* e, então, a malha de controle deve retornar à sua configuração original. Além do *status* do processo, o sistema de FDDC deve sinalizar o tipo de falha ocorrido (Z), permitindo um diagnóstico mais preciso e uma tomada de decisão mais assertiva.

Figura 4.8 - Ilustração da comunicação EMSO/Simulink



Neste problema não serão abordadas questões de re-sintonia dos parâmetros da malha de controle, visto que a ação de correção a ser implementada é uma medida emergencial e paliativa, devendo durar apenas o tempo necessário para que o reparo do sensor seja realizado.

Foram consideradas as seguintes falhas no sensor:

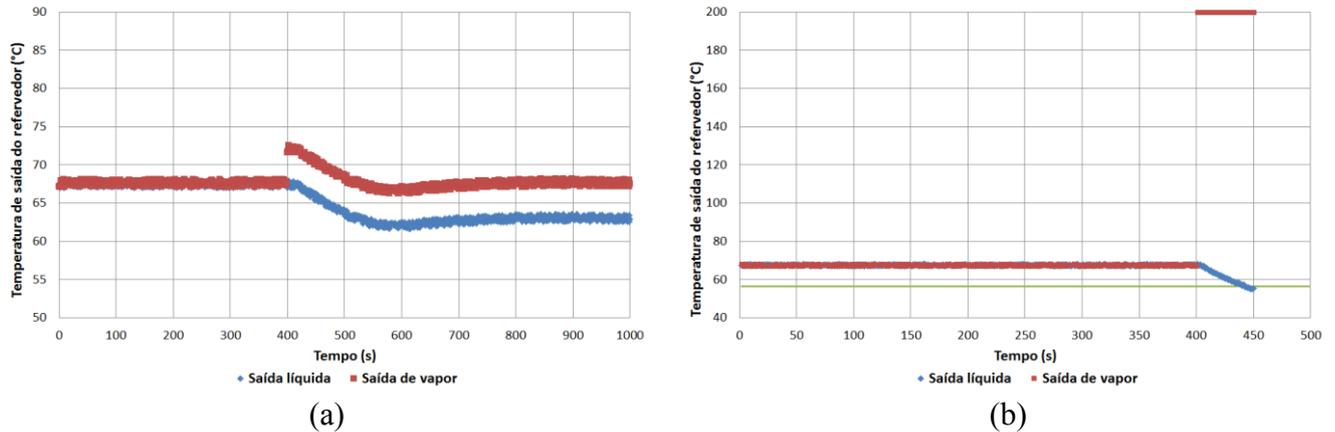
- i) desvio no valor da variável medida; e
- ii) rompimento do sensor, indicado pela mudança brusca do valor medido em direção ao fundo de escala ou ao início desta.

Ambos os tipos de falha em sensores de temperatura foram observados e estudados em outro sistema da mesma planta (Andrade, 2012; Sartori, 2012). A fim de aproximar os dados simulados do padrão encontrado nos dados reais de temperatura, foi inserido um ruído aleatório nos dados de temperatura de ambos os sensores, antes da entrada desses dados no sistema de FDDC. O ruído foi gerado a partir de blocos de geração de números aleatórios do Simulink com sementes distintas e alteradas a cada nova execução.

Na Figura 4.9 é possível observar o comportamento das indicações de temperatura de saída do refeedor, antes e depois da ocorrência da falha. Na falha onde ocorre desvio é possível perceber que logo que a temperatura muda aparentemente, a malha de controle age levando o valor da temperatura da saída de vapor para o *setpoint*. Porém, através da medida de temperatura da saída líquida, nota-se que a temperatura real sofreu um decréscimo e se estabilizou em uma temperatura abaixo do *setpoint*. Já na falha de rompimento do sensor de

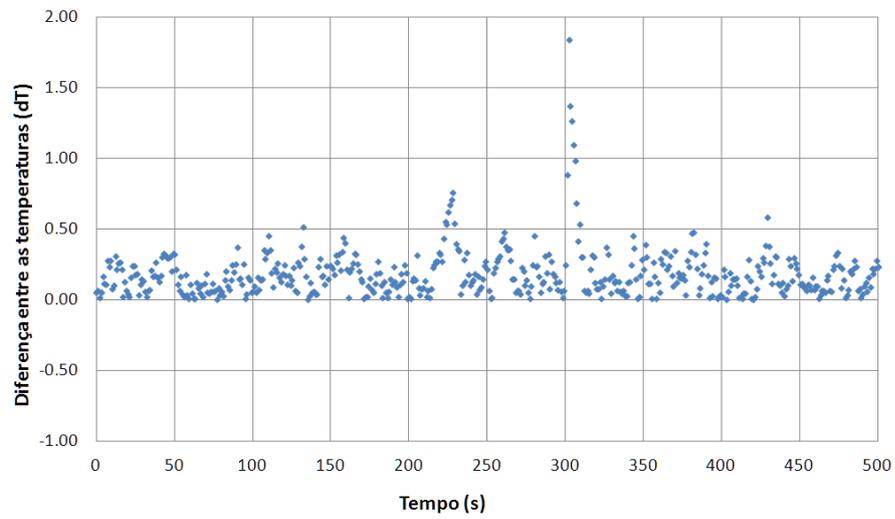
temperatura, a indicação da saída de vapor passa para o fim de escala e a temperatura real no refervedor desce até acionar o intertravamento.

Figura 4.9 - Falhas no sensor de temperatura: desvio (a) e rompimento (b)

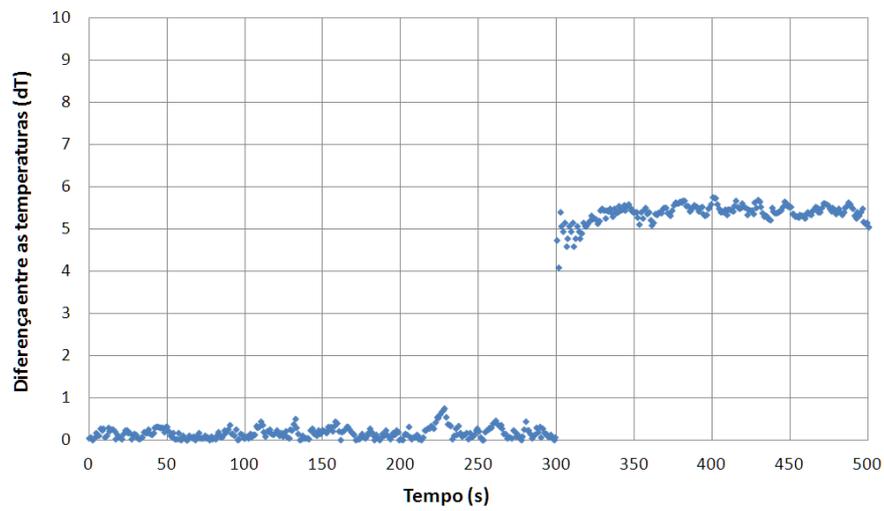


Baseado no conhecimento dos especialistas da planta, após a simulação dos dados foram identificados os padrões de diferença absoluta de temperatura (dT) entre os sensores do refervedor que representam o comportamento apresentado nos diferentes estados. O padrão que representa o estado de funcionamento normal do sensor foi chamado de padrão normal (N), e os padrões de falha foram chamados de desvio (D) para o estado desvio, e rompido (R) para o estado rompido. A Figura 4.10 mostra que a diferença (dT) é aproximadamente zero para o padrão normal, já a Figura 4.11 e a Figura 4.12 apresentam, respectivamente, diferença (dT) maior do que zero para o padrão desvio e muito maior do que zero para o padrão rompido.

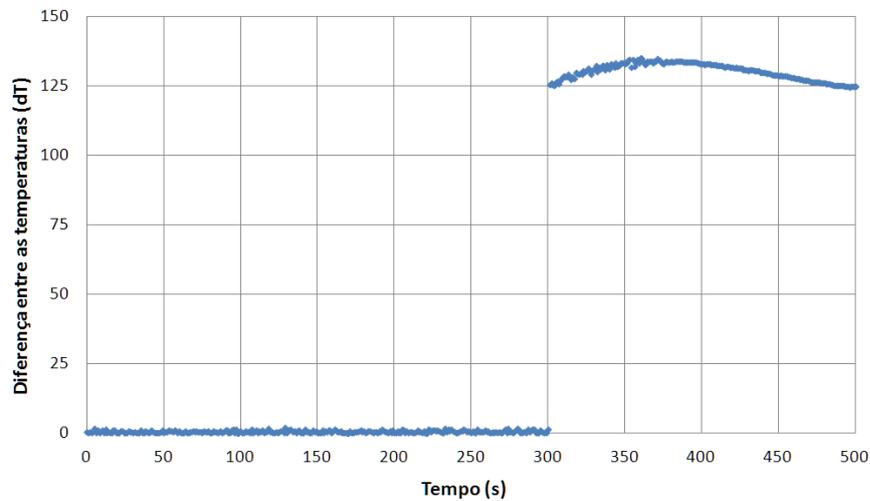
**Figura 4.10 - Diferença entre as temperaturas dos sensores de saída do refeedor:
padrão normal (N)**



**Figura 4.11 - Diferença entre as temperaturas dos sensores de saída do refeedor:
padrão desvio (D)**



**Figura 4.12 - Diferença entre as temperaturas dos sensores de saída do refeedor:
padrão rompido (R)**

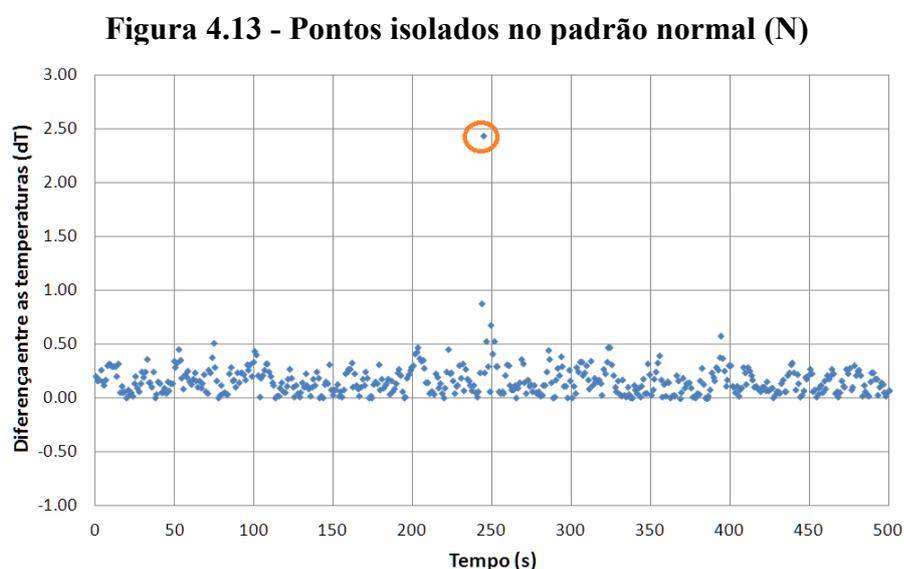


O estudo de caso apresentado é focado em dois tipos de falha de um sensor específico e, portanto, possui baixa complexidade. Para uma abordagem que busca uma solução simples e objetiva, um algoritmo de estrutura de decisão encadeada, conhecida como SE encadeados ou aninhados, é suficiente para construir o sistema. Nas estruturas de decisão (também denominadas de seleção ou condicionais), há uma ou mais decisões a serem tomadas, sempre com base em uma condição específica, pré-estabelecida (Carboni, 2003). Considerando a necessidade de ter um sistema capaz de detectar falhas diversas e mais complexas, uma abordagem utilizando redes neurais é interessante, pois a capacidade de aprender a partir de uma base de informações possibilita a aquisição do conhecimento necessário para interferir no funcionamento do sistema original, acusando a presença de uma dada falha. Ademais, algumas características de robustez e generalização das redes neurais fazem com que elas sejam uma ferramenta bastante utilizada para detecção e classificação de falhas, mesmo sob a presença de ruídos (Fernandes, 2007).

Portanto, foi desenvolvido um sistema FDCC utilizando um algoritmo de estrutura de decisão integrado ao modelo do processo e, a fim de demonstrar a possibilidade de abordar problemas mais complexos de forma semelhante, o mesmo sistema foi desenvolvido utilizando redes neurais e também integrado ao modelo do processo. Nas próximas seções são apresentados os sistemas FDCC desenvolvidos utilizando estas duas abordagens.

4.3.2. ALGORITMO DE DECISÃO: DESENVOLVIMENTO E RESULTADOS

De acordo com os dados reais de temperatura referentes aos sensores simulados, o desvio médio entre os valores medidos é de 2 °C e, por isso, este valor foi escolhido como limite de desvio aceitável, durante operação normal da coluna. Ainda nos dados reais, podem ser observados pontos isolados que indicam temperaturas discrepantes, o que pode ocorrer devido a erros de leitura do sensor, ou ainda, por um efeito intenso do ruído do processo. A Figura 4.13 mostra a representação desse efeito nos dados simulados.



O sistema de FDDC foi projetado para monitorar a diferença entre as medições e, caso ela ultrapasse o valor limite (2 °C), avaliar ao longo do tempo se a diferença (dT) se mantém, aumenta, ou diminui. Para garantir que a violação dessa regra não é causada pelo ruído do sistema, ou mesmo por erros aleatórios de leitura, o *flag* M é enviado ao EMSO apenas se a indicação de falha se mantiver por um tempo pré-determinado (5 s). A magnitude da diferença entre as temperaturas indica o tipo de falha (Z) ocorrida.

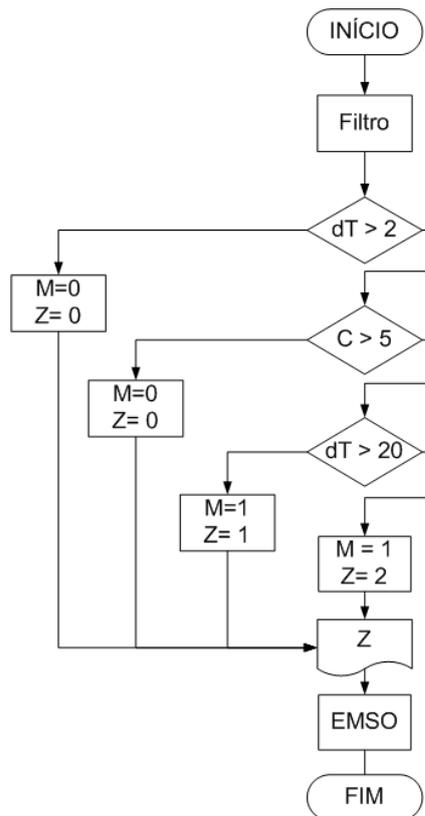
Considerando que em um processo real as variáveis medidas possuem ruídos, é necessário filtrar os dados antes da análise do comportamento das variáveis. A função de transferência discreta de primeira ordem (Equação 4.1) com parâmetros ajustados heurísticamente foi utilizada como filtro e, portanto, recebe os dados de temperatura brutos,

suaviza o ruído, e fornece ao algoritmo de decisão a diferença absoluta entre as temperaturas dos sensores.

$$G(z) = \frac{0.15 \cdot z}{z - 0.85} \quad (4.1)$$

Então, o sistema de FDDC consiste em um filtro e um algoritmo de decisão (Figura 4.14), cujas saídas são o *flag* M que assume valor 0 (zero) para operação normal e 1 (um) para evento de falha, e o indicador Z que pode ter valores 0 (zero), 1 (um) ou 2 (dois), sendo 0 (zero) para operação normal, 1 (um) para padrão desvio (D) e 2 (dois) para padrão rompido (R).

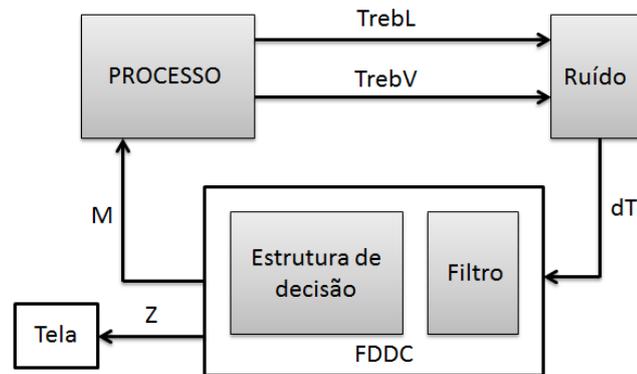
Figura 4.14 - Algoritmo da estrutura de decisão do sistema FDDC



Uma visão geral do sistema FDCC, baseado em algoritmo de decisão, integrado ao modelo do processo em EMSO pode ser observada na Figura 4.15, onde C é uma variável

incremental que funciona como contador de interações (com *reset*) e nesse caso equivale ao tempo em segundos.

Figura 4.15 - Desenho esquemático da comunicação processo/sistema FDDC



Foram realizadas diversas simulações para cada um dos padrões de falha, alterando a magnitude do desvio ou ainda o momento de introdução da falha. As figuras a seguir apresentam resultados de duas simulações, uma com falha tipo desvio e outra com falha tipo rompido. A falha ocorre aos 300 segundos da simulação e o tempo de reparo do sensor foi estipulado em 500 segundos, e por isso é possível notar a mudança do *flag* de *status* depois de decorrido esse tempo (800 s). O sistema de detecção e diagnóstico de falhas desenvolvido foi capaz de detectar a ocorrência de falha no sensor de temperatura, bem como indicar o tipo de falha em todos os casos simulados. Não foram registrados casos de falso positivo, ou seja, a detecção de uma falha quando esta não ocorreu e, principalmente, não ocorreram casos de falso negativo e, portanto, nenhuma falha existente deixou de ser detectada.

Na simulação onde ocorre a falha desvio (Figura 4.16), é possível notar que a temperatura real do refeedor (indicada pelo sensor da saída líquida) não se altera após a ocorrência da falha, devido à rápida ação do sistema de FDDC. Da mesma forma, quando o *flag* M indica que o sensor da saída de vapor volta a operar normalmente, o processo não é perturbado. No caso de rompimento do sensor (Figura 4.17), a mudança de temperatura é brusca e por isso o sistema é levemente perturbado, devido à reação do controlador. Contudo, a rápida reconfiguração da estrutura da malha de controle impede que haja impacto no processo.

Figura 4.16 - Simulação integrada com falha Desvio (D): temperaturas marcadas pelos sensores de saída do refeedor (a); diferença absoluta entre as temperaturas de saída e valor dos indicadores M e Z (b)

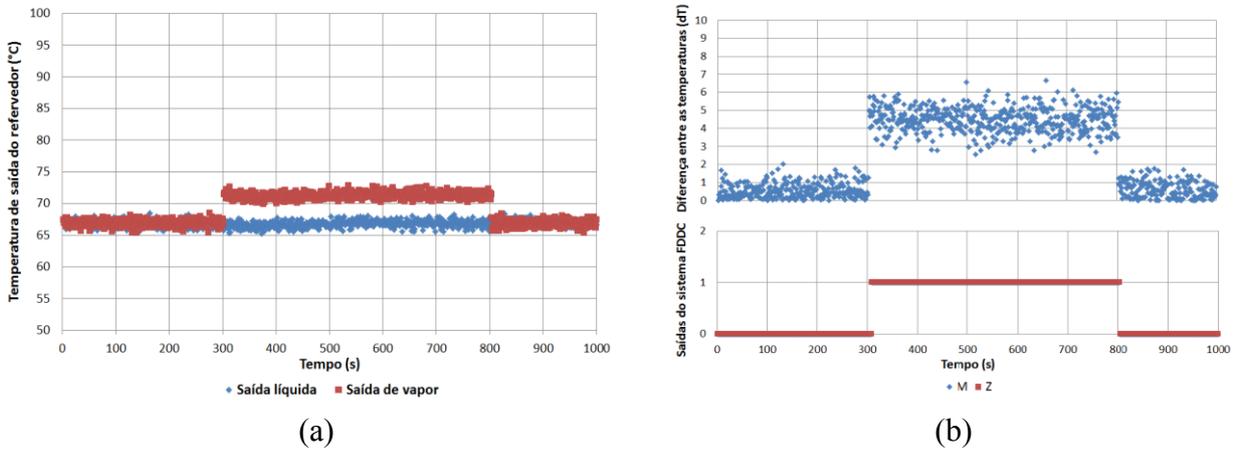
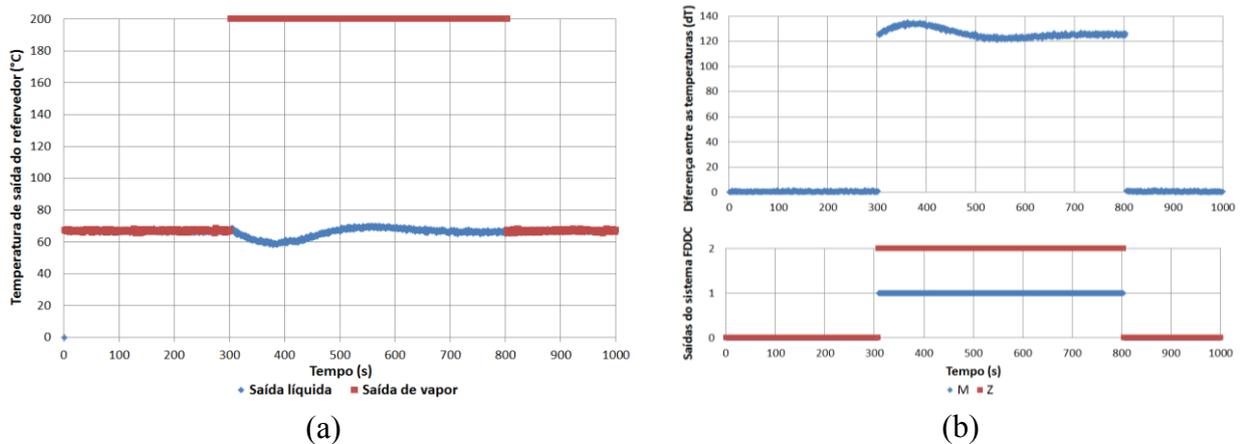


Figura 4.17 - Simulação integrada com falha Rompido (R): temperaturas marcadas pelos sensores de saída do refeedor (a); diferença absoluta entre as temperaturas de saída e valor dos indicadores M e Z (b)



Para verificar a possibilidade de falhas em outros sensores ou equipamentos interferirem no sistema desenvolvido, as outras falhas simuladas anteriormente (Quadro 4.1) foram inseridas na simulação em que o sistema de FDDC foi implementado. Nenhuma das falhas simuladas causou qualquer tipo de interferência no sistema, não foram detectadas falhas inexistentes no sensor de temperatura do refeedor, nem mesmo quando a temperatura no refeedor foi alterada anormalmente como consequência de uma falha em outro ponto da coluna. Portanto, o sistema desenvolvido obteve resultados satisfatórios e demonstrou como

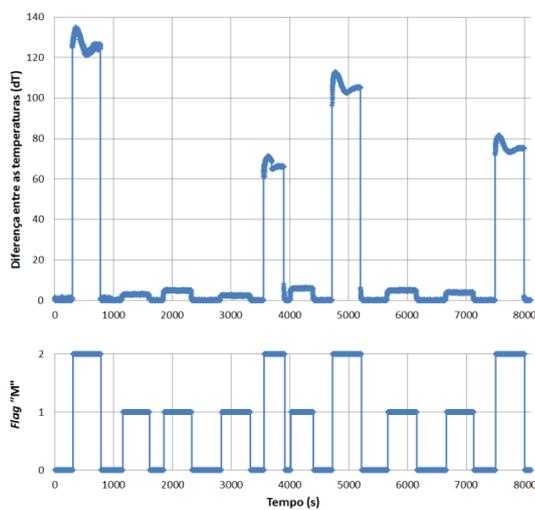
uma detecção eficiente, atrelada a uma simples ação de correção, faria com que o bom desempenho do diagnóstico fosse traduzido em diminuição dos custos operacionais e no aumento da confiabilidade e da segurança do processo.

A estimativa dos benefícios de sistemas de detecção, diagnóstico e correção de falhas pode ser realizada utilizando a abordagem proposta por Sartori (2012), onde estudos prévios de confiabilidade viabilizam a estimativa financeira e a melhoria na segurança de processos.

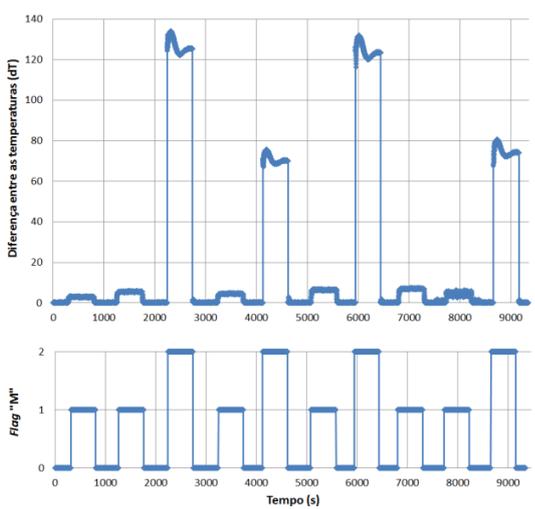
4.3.3. REDES NEURONAIS: DESENVOLVIMENTO E RESULTADOS

Os conjuntos de dados para treinamento (A), validação (B) e teste (C) da rede neuronal foram obtidos através da simulação dinâmica do processo desenvolvida no EMSO (Figura 4.18). Cada conjunto contém dados referentes a todos os padrões identificados e possuem duração média de duas (2) horas e trinta (30) minutos. Assim como no sistema anterior, o padrão que representa o estado de funcionamento normal do sensor foi chamado de padrão normal (N), e os padrões de falha foram chamados de desvio (D) para o estado desvio, e rompido (R) para o estado rompido.

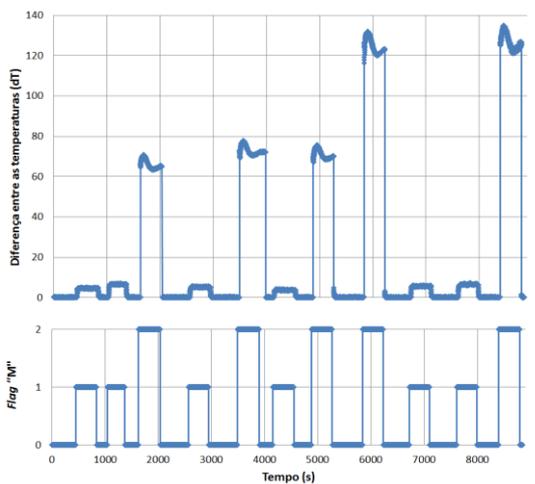
Figura 4.18 - Conjuntos de treinamento (a), validação (b) e teste (c) para a rede neuronal



(a)



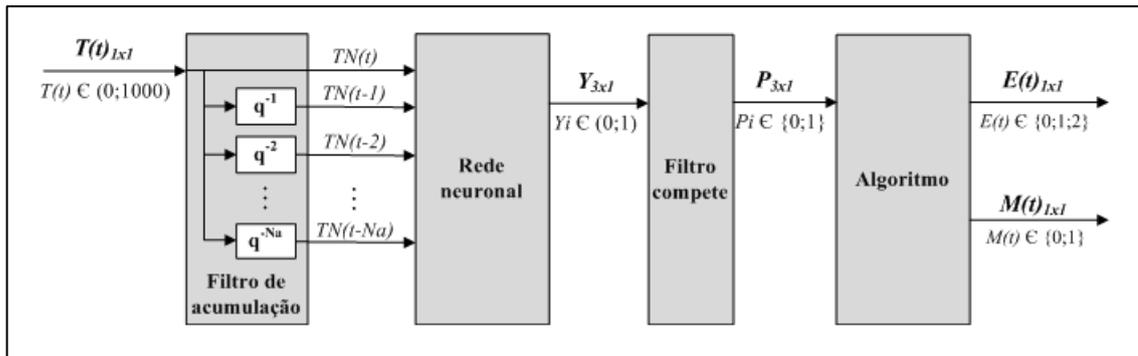
(b)



(c)

O sistema de FDDC desenvolvido é composto de um filtro de acumulação, uma rede neuronal, um filtro do tipo compete e uma estrutura de decisão (Figura 4.19). A entrada do sistema (dT) corresponde ao valor da diferença absoluta entre as temperaturas indicadas pelos sensores de temperatura do refrigerador, de forma análoga ao sistema desenvolvido anteriormente. O filtro de acumulação agrupa os pontos referentes a cada padrão de acordo com o número de tempos anteriores (Na) estabelecido. As saídas do filtro (TN) correspondem a uma série temporal composta pelas diferenças dT normalizadas entre 0 (zero) e 1 (um). Desta forma, as entradas da rede neuronal equivalem a dT no tempo atual e nos Na tempos anteriores estabelecidos. Cada uma das 3 (três) saídas da rede neuronal (Y) equivale a um dos padrões (N, D, R) com respostas possíveis entre 0 (zero) e 1 (um).

Figura 4.19 - Esquemático do sistema de FDDC desenvolvido com base em rede neuronal



O filtro compete compara os valores das suas três entradas (que são as saídas da rede) e atribui às saídas (P) o valor 1 para a maior entrada e zero para todas as outras, perfazendo o número de saídas igual ao total de entradas. Apenas uma das três saídas será igual a 1 e todas as outras serão nulas, sendo que quando existe mais de uma entrada igual ao maior valor, será atribuído o valor 1 ao primeiro padrão equivalente. O objetivo deste filtro é fazer com que exista apenas uma classificação para cada ponto analisado.

A estrutura de decisão possui duas saídas, a primeira determina o valor do *flag* (M) enviado ao EMSO, que indica a existência, ou não, de uma falha, e a segunda indica o tipo de falha detectada através de uma saída (Z) com valores possíveis zero, que equivale ao estado

normal (padrão N), 1, que corresponde ao estado desvio (padrão D), ou 2, que representa o estado rompido (padrão R). As saídas deste filtro, $E(t)$, representam o estado do sensor diagnosticado pelo sistema para o tempo atual (t).

A rede neuronal utilizada foi do tipo *Multi-Layer Perceptron* (MLP, *perceptron* multicamadas) com uma única camada intermediária e número de neurônios da camada de saída igual ao número de padrões (três). A estrutura do sistema é idêntica à de uma rede neuronal estática do tipo *feedforward*, onde os sinais propagam-se apenas para frente, não existindo realimentação. Para incorporar à rede o comportamento dinâmico dos padrões, foi aplicada a abordagem utilizada por Souza Jr. (1993) e avaliada por Embiruçu (1998), onde o número de entradas da rede é igual ao número de tempos anteriores mais um. Por isso, foram considerados como entradas, além do valor atual da diferença entre as temperaturas dos sensores (dT), também seus valores em tempos anteriores.

Testes preliminares realizados chegaram ao valor de 2 tempos anteriores para ter a dinâmica dos padrões bem representada. Assim, o valor correspondente de 3 entradas foi fixado preliminarmente na definição do número de neurônios ótimo da camada intermediária. Foram utilizados neurônios com função de transferência do tipo tangente hiperbólica (*tansig*) na camada intermediária, bem como na camada de saída:

$$y(x) = \text{tansig}(x) = \frac{2}{e^{-2 \cdot x} + 1} - 1 \quad (4.2)$$

A partir do trabalho desenvolvido em Sartori (2012), foi escolhido como método de definição de estrutura ótima da rede neuronal a Validação Cruzada Dinâmica (VCD). A mesma metodologia de treinamento e validação foi adotada, utilizando os padrões de falha fornecidos pela simulação. Para o aprendizado da rede foi utilizado o algoritmo de treinamento *backpropagation* (retropropagação) Marquardt (Hagan e Menhaj, 1994), com estimativas iniciais de acordo com Nguyen e Widrow (1990).

O número ótimo de 2 (dois) neurônios para a camada intermediária foi encontrado com a metodologia VCD. Esta configuração possui o menor erro quadrático médio de validação (aproximadamente igual a 0.08). O ajuste fino do número de tempos anteriores foi feito através da análise de sensibilidade do erro quadrático médio, variando este número de

tempos anteriores. O valor de 2 (dois) tempos anteriores foi mantido, e equivale a um número de entradas igual a 3 (três).

A Figura 4.20 representa a rede neuronal final escolhida para compor o sistema de FDDC. Esta rede neuronal possui 3 (três) entradas, uma camada intermediária com 2 (dois) neurônios *tansig*, 3 (três) neurônios *tansig* na camada de saída e 17 (dezessete) parâmetros. Na figura, *TN* é a entrada da rede, *n1*, *n2* e *a1* são saídas parciais, de acordo com as Equação (4.3) a Equação (4.6), *Y* é a saída final da rede, *IW^{1,1}* e *LW^{2,1}* são as matrizes dos pesos da primeira e da segunda camadas, respectivamente, e *b1* e *b2* são os *bias* (desvios) da primeira e da segunda camadas, respectivamente.

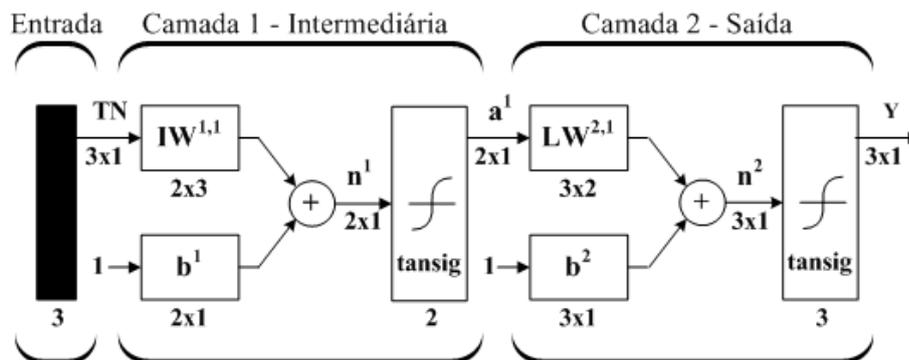
$$n^1 = IW^{1,1} \times TN + b^1 \quad (4.3)$$

$$a^1 = \text{tansig}(n^1) \quad (4.4)$$

$$n^2 = LW^{2,1} \times a^1 + b^2 \quad (4.5)$$

$$Y = \text{tansig}(n^2) \quad (4.6)$$

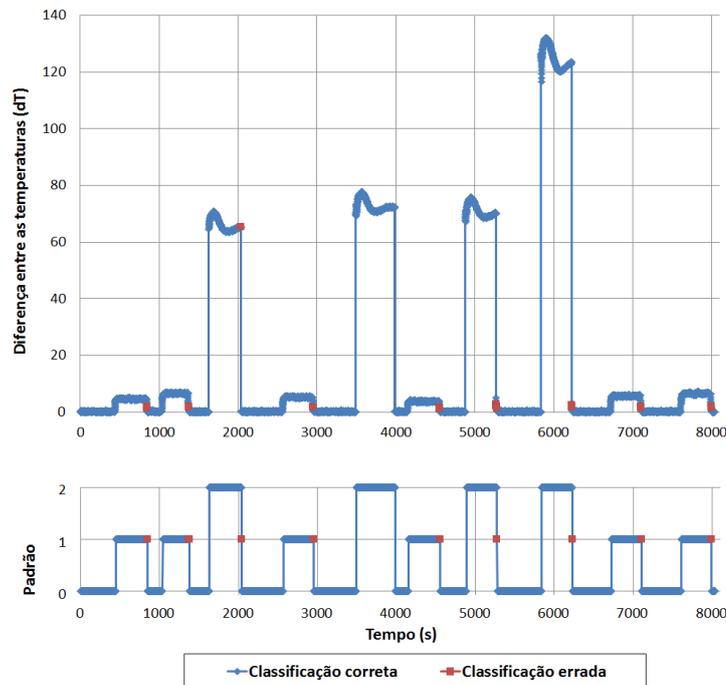
Figura 4.20 - Rede neuronal final do sistema FDDC



O sistema obtido através do método VCD possui exatidão total (percentual total de acerto) igual a 99.16% para o conjunto A, 99.23% para o conjunto B e 99.2% para o conjunto C. Quase 100% dos erros são de falsos positivos, ou seja, o sistema detecta uma falha quando ela não existe. Apenas um ponto em cada um dos conjuntos A e B foi detectado como falso negativo, um estado de falha teoricamente não detectado, sendo que no conjunto C nenhum caso deste tipo ocorreu. Na Figura 4.21 são apresentados os resultados da rede neuronal para o

conjunto de teste, sendo a entrada da rede a diferença entre as temperaturas, e a saída a classificação do padrão.

Figura 4.21 - Resultados da rede neuronal com pontos classificados de forma errada em destaque



Analisando os resultados atentamente percebe-se que os erros da rede estão sempre localizados nos pontos imediatamente anteriores ou posteriores a uma mudança de estado, ou seja, logo antes de uma falha ocorrer ou logo após esta ser corrigida, o que é claramente um efeito do transiente provocado pelo início ou fim do estado de falha. Portanto, os resultados obtidos foram considerados satisfatórios e atendem perfeitamente os objetivos deste estudo.

Concluído o desenvolvimento do sistema FDDC baseado em redes neurais, o passo seguinte foi integrá-lo ao modelo da coluna desetanizadora desenvolvido em EMSO, via MATLAB/Simulink, de forma análoga à apresentada na seção 4.3. O bloco *S-function* foi utilizado para integrar o sistema FDDC ao sistema em *Simulink* desenvolvido anteriormente, permanecendo com a mesma estrutura apresentada na Figura 4.8.

Simulações com ambos os tipos de falha foram realizadas com sucesso. O modelo da coluna respondeu de forma satisfatória, bem como, o sistema de FDDC, que conseguiu

detectar corretamente todos os eventos de falha. Nos casos em que a rede neuronal realizou a detecção de forma equivocada (falso positivo ou falso negativo), o modelo dinâmico da coluna demonstrou que o processo é capaz de absorver os erros sem sofrer impacto significativo. Este comportamento era esperado, pois como dito anteriormente, esse tipo de erro ocorre normalmente no transiente entre os estados (normal-falha ou falha-normal) e não dura mais do que 5 (cinco) segundos para ser corrigido.

Comparado ao sistema FDDC desenvolvido na seção anterior, o sistema baseado em rede neuronal possui tempo de detecção menor (1 s), permitindo ao processo não sentir nenhum impacto com a ocorrência de falhas no sensor, mesmo em caso de rompimento. Isso é facilmente percebido através da estabilidade da temperatura de saída líquida do refulvedor ao longo do tempo (Figura 4.22, Figura 4.23). Contudo, para falhas com padrão desvio, se a diferença é relativamente grande, como na Figura 4.24, a rede pode errar o tipo de falha, indicando rompimento no lugar de desvio. Já se a diferença for pequena, muito próxima da variabilidade da medida (Figura 4.25), os erros são na detecção da falha. Em todo caso, como dito anteriormente, os erros da rede são mínimos e não afetam o desempenho do sistema.

Assim, o sucesso da integração do sistema FDDC, baseado em rede neuronal, ao modelo dinâmico do processo aponta uma excelente oportunidade de desenvolvimento de sistemas mais complexos, projetados para monitorar múltiplas falhas. Diante de um modelo dinâmico representativo do processo, é possível gerar um grande número de possíveis condições de falha e obter os dados necessários, e frequentemente escassos, para a construção de um sistema de FDDC baseado em métodos quantitativos.

Figura 4.22 - Simulação integrada (FDDC com rede neuronal) com padrão rompido (fim de escala): temperaturas marcadas pelos sensores de saída do refervedor (a); diferença absoluta entre as temperaturas de saída e valor dos indicadores M e Z (b)

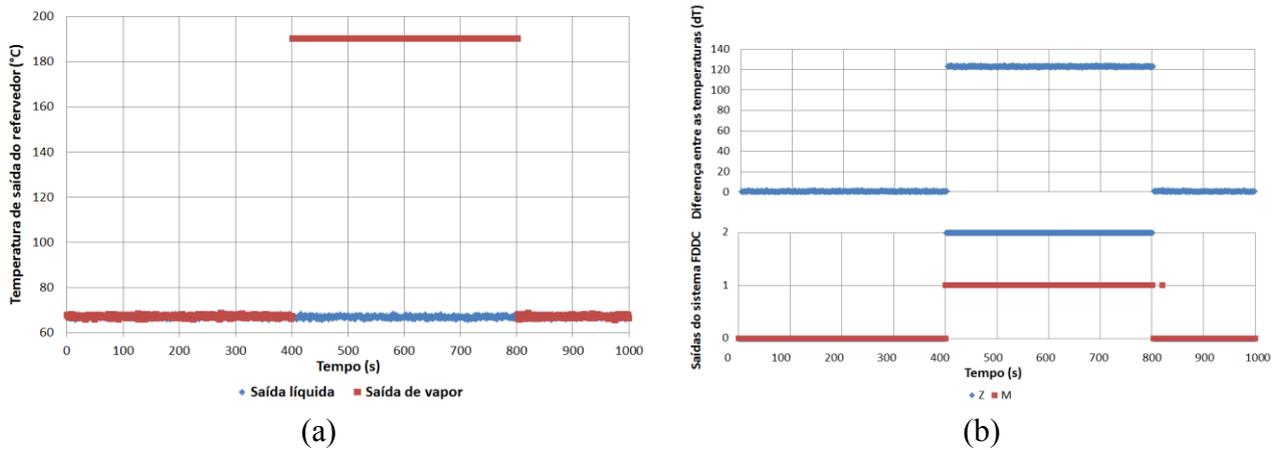


Figura 4.23 - Simulação integrada (FDDC com rede neuronal) com padrão rompido (início de escala): temperaturas marcadas pelos sensores de saída do refervedor (a); diferença absoluta entre as temperaturas de saída e valor dos indicadores M e Z (b)

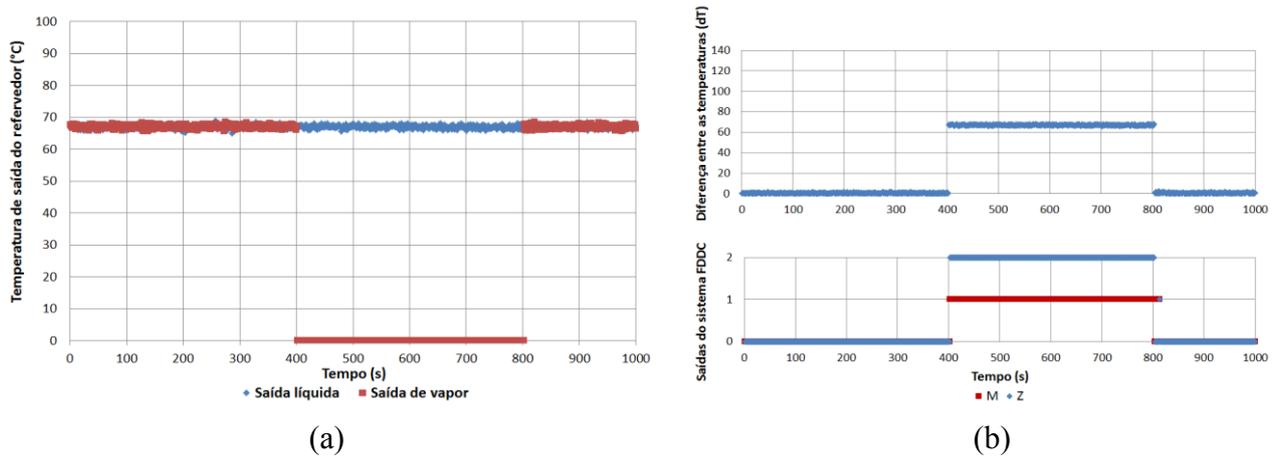


Figura 4.24 - Simulação integrada (FDDC com rede neuronal) com padrão desvio (-6,5 °C): temperaturas marcadas pelos sensores de saída do refeedor (a); diferença absoluta entre as temperaturas de saída e valor dos indicadores M e Z (b)

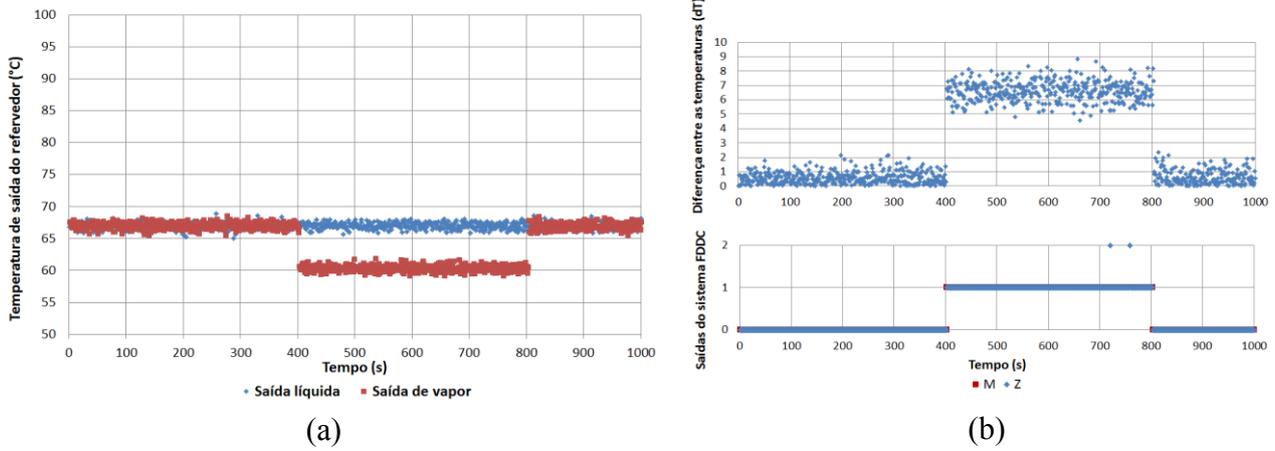
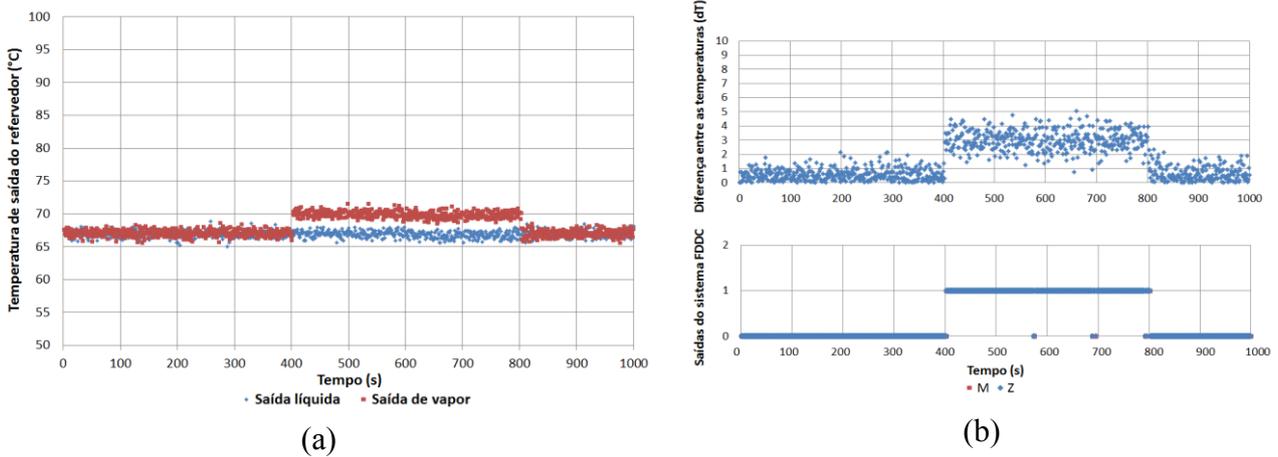


Figura 4.25 - Simulação integrada (FDDC com rede neuronal) com padrão desvio (+3,0 °C): temperaturas marcadas pelos sensores de saída do refeedor (a); diferença absoluta entre as temperaturas de saída e valor dos indicadores M e Z (b)



5. Conclusões e Sugestões para Trabalhos Futuros

5.1. CONCLUSÕES

As aplicações de simulação de processos nos estudos de comportamento de unidades de processamento de gás natural são bem abordadas na literatura, contudo existe uma lacuna em relação ao uso dessas simulações no desenvolvimento de sistemas de detecção, diagnóstico e correção de falhas para esses sistemas. Um sistema de FDDC pode garantir o aumento da vida útil do processo e a extensão do seu ciclo, através da detecção precoce da falha e de uma rápida ação de correção.

Diante da disponibilidade de informações de uma unidade de processamento de gás natural, sua coluna desetanizadora foi escolhida para o estudo e desenvolvimento de um sistema de FDDC automático, capaz de monitorar a planta industrial em tempo real e agir rapidamente sobre as falhas detectadas. Para entender o comportamento do processo em situações de falha e suas reações às intervenções de correção, um modelo matemático representativo da coluna foi construído, utilizando a linguagem de modelagem do simulador de processos EMSO (*Environment for Modeling, Simulation, and Optimization*). Portanto, a inovação proposta nesta dissertação foi integrar, em um único ambiente de simulação, a modelagem dinâmica de uma unidade real considerada de alta complexidade a um sistema de FDDC que possui a etapa de correção automática.

A modelagem da coluna desetanizadora foi desenvolvida com base em dados reais de uma Unidade de Recuperação de Gás Natural (URGN). A coluna desetanizadora é uma coluna multicomponente, complexa, com perfil de temperatura íngreme e realiza uma destilação prato a prato, que produz um gás contendo baixo teor de C₃₊ e um produto líquido contendo baixo teor de etano (C₂). Simplificações na modelagem foram necessárias, porém os resultados do estado estacionário foram compatíveis com os dados reais e, de acordo com o conhecimento de especialistas da Unidade, a dinâmica do processo foi bem representada. Por fim, a simulação desenvolvida reproduziu as condições típicas da unidade de processamento de gás natural e foi suficiente para elaborar os estudos propostos.

Os casos de mau funcionamento e falhas em colunas de destilação estão bem relatados nas publicações da área de detecção e diagnóstico de falhas, sendo os seguintes os tipos de falha mais encontrados em colunas de destilação: aumento ou diminuição da vazão de vapor para o refeedor por falha do sensor de temperatura; alteração na composição da carga; e

falha no transmissor da malha de nível do vaso de topo. A partir das informações do HAZOP da coluna e das falhas citadas anteriormente, seis falhas foram definidas e testadas, e cinco delas foram simuladas com êxito. Em todos os casos, após a ocorrência da falha, rapidamente uma situação limite foi alcançada (transbordamento/secagem de vaso ou refeedor, acionamento do sistema de intertravamento de segurança por limites de temperatura) e a simulação interrompida.

Para a implementação do sistema de FDDC, foi escolhida a falha pertencente à malha de controle de temperatura do refeedor, cuja falha no sensor de temperatura leva ao aumento/redução do fluxo de calor para o refeedor. A estratégia de detecção foi baseada na redundância de sensores disponíveis no refeedor, pois além do sensor de temperatura do vapor que sai do refeedor em direção à coluna (malha de temperatura), existe um sensor de temperatura na saída líquida do refeedor, que não pertence a nenhuma malha de controle. Foram consideradas as seguintes duas falhas no sensor: desvio no valor da variável medida; e rompimento do sensor, indicado pela mudança brusca do valor medido em direção ao fundo de escala ou ao início desta. Padrões na diferença absoluta de temperatura (dT) entre o sensores do refeedor foram identificados e caracterizados. O padrão que representa o estado de funcionamento normal do sensor foi chamado de padrão normal (N), e os padrões de falha foram chamados de desvio (D) para o estado desvio, e rompido (R) para o estado rompido. A diferença (dT) é aproximadamente zero para o padrão normal, maior do que zero para o padrão desvio e muito maior do que zero para o padrão rompido.

Como o problema escolhido é focado em dois tipos de falha de um sensor específico, um algoritmo de estrutura de decisão encadeada foi suficiente para construir o sistema de FDDC de forma simples e objetiva. Porém, uma abordagem utilizando redes neurais também foi realizada a fim de demonstrar a possibilidade de abordar problemas mais complexos de forma semelhante. O sistema de FDDC, em ambas as abordagens, recebe como entrada as medições de temperatura no refeedor e envia para o EMSO um *flag* (M) indicando o *status* do processo. Ao receber uma indicação de falha do sensor, a malha de controle em questão tem sua PV (*Process Variable*) alterada automaticamente para o valor da medição redundante. Ao ser sanado o problema no sensor, o sistema percebe o padrão de comportamento normal, alterar novamente o *flag* e, então, a malha de controle deve retornar à sua configuração original. Além do *status* do processo, o sistema de FDDC sinaliza o tipo de falha (Z) ocorrida.

O sistema de FDDC baseado no algoritmo de decisão encadeada foi projetado para monitorar a diferença entre as medições e, caso ela ultrapasse o valor limite, avaliar ao longo do tempo essa diferença (dT) para garantir que a violação dessa regra não seja causada pelo ruído do sistema ou mesmo por erros aleatórios de leitura. O *flag* é enviado ao EMSO apenas se a indicação de falha se mantiver por um tempo pré-determinado, e a magnitude da diferença entre as temperaturas indica o tipo de falha. Portanto, o sistema de FDDC consiste de um filtro e de um algoritmo de decisão, cujas saídas são o *flag* M que assume valores 0 (zero) para operação normal e 1 (um) para evento de falha, e o indicador Z que pode ter valores 0 (zero), 1 (um) ou 2 (dois), sendo 0 (zero) para operação normal, 1 (um) para padrão desvio (D) e 2 (dois) para padrão rompido (R).

De forma análoga, o sistema de FDDC baseado em rede neuronal é composto de um filtro de acumulação, uma rede neuronal, um filtro do tipo compete e uma estrutura de decisão. A entrada do sistema (dT) corresponde ao valor da diferença absoluta entre as temperaturas indicadas pelos sensores de temperatura do refeedor e as saídas da rede equivalem a um dos padrões (N, D, R) com respostas possíveis entre 0 (zero) e 1 (um). A rede neuronal final, obtida através do método de validação cruzada dinâmica, possui 3 (três) entradas, uma camada intermediária com 2 (dois) neurônios *tansig*, 3 (três) neurônios *tansig* na camada de saída e 17 (dezesete) parâmetros. O sistema possui exatidão total (percentual total de acerto) igual a 99.16% para o conjunto de treinamento, 99.23% para o conjunto de validação e 99.2% para o conjunto de teste. Estes resultados atendem perfeitamente aos objetivos deste trabalho.

A integração dos sistemas de FDDC com o modelo do processo foi realizada através da interface de comunicação EMSO/MATLAB, que utiliza um bloco *S-function* do Simulink. Foram realizadas diversas simulações para cada um dos padrões de falha, alterando a magnitude do desvio ou, ainda, o momento de introdução da falha. O sistema de detecção, diagnóstico e correção de falhas baseado no algoritmo de estrutura de decisão foi capaz de detectar a ocorrência de falha no sensor de temperatura, bem como indicar o tipo de falha em todos os casos simulados. Neste sistema não foram registrados casos de falso positivo, ou seja, a detecção de uma falha quando esta não ocorreu e, principalmente, não ocorreram casos de falso negativo e, portanto, nenhuma falha existente deixou de ser detectada. Simulações com ambos os tipos de falha utilizando o sistema de FDDC baseado em rede neuronal também foram realizadas com sucesso, conseguindo o sistema detectar corretamente todos os

eventos de falha. Em casos onde a rede neuronal realizou a detecção de forma equivocada (falso positivo ou falso negativo), o modelo dinâmico da coluna demonstrou que o processo é capaz de absorver os erros sem sofrer impacto significativo.

Por fim, para investigar os possíveis efeitos no sistema de FDDC de uma falha em outros elementos da coluna, foram realizados testes com os outros tipos de falha, previamente simulados. Nenhuma das falhas simuladas causou qualquer tipo de interferência no sistema, e não foram detectadas falhas inexistentes no sensor de temperatura do refeedor, nem mesmo quando a temperatura no refeedor foi alterada anormalmente como consequência de uma perturbação ou falha em outro ponto da coluna. Um sistema de FDDC desenvolvido para detectar qualquer um dos tipos de falhas identificados necessita de uma ferramenta robusta, e o uso de redes neurais indicou uma excelente oportunidade de desenvolvimento de sistemas mais complexos, projetados para monitorar múltiplas falhas.

Em suma, os sistemas desenvolvidos promoveram uma detecção eficiente e demonstraram como a etapa de correção automática é capaz de manter o bom desempenho da unidade, evitando os custos operacionais de paradas não programadas, bem como aumentando a confiabilidade e segurança do processo. Portanto, a abordagem proposta para o desenvolvimento de sistemas de detecção, diagnóstico e correção de falhas utilizando modelos dinâmicos validados do processo para obter os dados necessários, e frequentemente escassos, gerar um grande número de possíveis condições de falha e, posteriormente, realizar testes de eficácia do sistema, mostrou-se antes de tudo um instrumento capaz de dar conta de tal problema, abordando um relevante caso industrial real. Apesar da complexidade do sistema, o problema de detecção, diagnóstico e correção dele derivado que foi aqui investigado é relativamente simples. Neste sentido, provou-se que uma abordagem simples e robusta, baseada em uma estrutura de decisão encadeada, pode resolver o problema, e ser implementado em tempo real de forma bastante fácil, rodando *on-line* de forma independente do modelo fenomenológico desenvolvido. Para problemas de detecção e diagnóstico mais complexos, foi desenvolvida também uma abordagem mais genérica, baseada em redes neurais, que, embora de desenvolvimento um pouco mais complexo, pode também ser implementado em tempo real, rodando *on-line* também de forma independente do modelo fenomenológico. Além disso, a abordagem desenvolvida pode servir ainda como uma ferramenta didática de auxílio ao estudo e ensino de sistemas de FDDC para plantas industriais.

5.2.SUGESTÕES PARA TRABALHOS FUTUROS

Durante o desenvolvimento deste trabalho algumas oportunidades de trabalhos futuros foram levantadas visando à continuação das pesquisas na área:

- Aplicar no caso de estudo apresentado nessa dissertação a metodologia apresentada em Sartori (2012) para estimativa de benefícios de sistemas FDDC;
- Utilizar dados reais de falhas do sensor da malha de temperatura do refeedor apresentada nesse estudo para avaliar o desempenho dos sistemas FDDC desenvolvidos;
- Desenvolver o modelo da coluna desetanizadora em um *software* que possua ferramentas próprias para geração de falhas (DYNSIM, por exemplo), e simular todas as falhas propostas nesse trabalho, incluindo as que não foram simuladas com sucesso no EMSO. Posteriormente, integrar o modelo ao sistema FDDC;
- Desenvolver um sistema FDDC, baseado em redes neurais, capaz de detectar e corrigir, em tempo real, todas as falhas apresentadas e simuladas na Seção 4.2 desta dissertação;
- Desenvolver uma interface gráfica para o sistema de FDDC desenvolvido, semelhante às interfaces de operação, com o objetivo de auxiliar o ensino e o treinamento de pessoas;
- Realizar um levantamento das etapas e custos da implantação de um sistema FDDC em uma planta real, a fim de melhorar as estimativas dos benefícios econômicos envolvidos.

6. Referências Bibliográficas

- ABNT (1994). Confiabilidade e manutenibilidade. NBR 5462, *Associação Brasileira de Normas Técnicas (ABNT)*, Rio de Janeiro, Brasil;
- Afonso, P., Ferreira, J. e Castro, J. (1998). Sensor fault detection and identification in a pilot plant under process control. *Chemical Engineering Research & Design*, v. 76, pp. 490–498;
- Akhlaghi, P., Kashanipour, A. R. e Salahshoor, K. (2008). Intelligent fault diagnosis of distillation column system based on PCA and multiple ANFIS. *Conference on Cybernetics and Intelligent Systems*, pp.905–910;
- Almehaideb, R. A., Al-khanbashi, A. S., Abdulkarim, M. e Ali, M. A. (2000). EOS tuning to model full field crude oil properties using multiple well fluid PVT analysis. *Journal of Petroleum Science and Engineering*, v. 26, pp. 291–300;
- Amaro, C., Requião, R. e Embiruçu, M. (2011). Dynamic Modeling of a Deethanizer Column in a Natural Gas Processing Plant. *International Conference on Modeling, Simulation and Control*, v. 10, pp. 12–16;
- Andrade, V. E. (2012). Sistema de detecção e diagnóstico de falhas em sensores de um compressor de gás de natural utilizando lógica fuzzy tipo-2. Dissertação de mestrado, UFBA, Salvador, Brasil;
- ANP (2013a). Tendências de Longo Prazo no Cenário Energético Mundial: Agência Internacional de Energia – WEO 2012. *Agência Nacional do Petróleo, Gás Natural e Biocombustíveis, ANP*. Disponível em: [<http://www.anp.gov.br/?id=2797>]. Acessado em Maio de 2013;
- ANP (2013b). Tendências de Longo Prazo no Cenário Energético Mundial: WOO2012 Análise Comparativa com o WEO2012. *Agência Nacional do Petróleo, Gás Natural e Biocombustíveis, ANP*. Disponível em: [<http://www.anp.gov.br/?id=2797>]. Acessado em Maio de 2013;
- ASPEN (2013). Aspen Dynamics. Disponível em: [<http://www.aspentech.com/products/aspen-dynamics.aspx>]. Acessado em Junho de 2013;

- Ayoubi, M., e Isermann, R. (1997). Neuro-fuzzy systems for diagnosis. *Fuzzy sets and Systems*, v. 89, pp. 289–307;
- Beard, R. V. (1971). Failure accommodation in linear systems through self-reorganization. Tese de doutorado, MIT, Massachusetts, USA;
- Behbahani, R. M., Jazayeri-Rad, H., e Hajmirzaee, S. (2009). Fault Detection and Diagnosis in a Sour Gas Absorption Column Using Neural Networks. *Chemical Engineering & Technology*, v. 32, pp. 840–845. doi:10.1002/ceat.200800486;
- Bishop, C. M. (1995). Neural Networks for Pattern Recognition. *Oxford University Press*, New York, USA;
- Blázquez, L. F. e Miguel, L. J. (2005). Additive fault detection in nonlinear dynamic systems with saturation. *ISA Transactions*, v. 44, pp. 515–38;
- Brydon, D. A., Cilliers, J. J. e Willis, M. J. (1997). Classifying pilot-plant distillation column faults using neural networks. *Control Engineering Practice*, v. 5, pp. 1373–1384;
- Carboni, I. de F. (2003). Lógica de programação. 1a. ed., Thomson, São Paulo, Brasil;
- Chiang, L. H., Russel, E. L., e Braatz, R. D. (2001). Fault detection and diagnosis in industrial systems. 1a. ed., Springer, London, UK;
- Cordeiro, A. de F. (2011). Estudo de simulação e controle de uma unidade de processamento de gás natural. Dissertação de mestrado, UFRJ, Rio de Janeiro, Brasil;
- Darwish, N. A. e Hilal, N. (2008). Sensitivity analysis and faults diagnosis using artificial neural networks in natural gas TEG-dehydration plants. *Chemical Engineering Journal*, v. 137, pp. 189–197. doi:10.1016/j.cej.2007.04.008;
- Elnemr, H. A. e Elewa, M. M. (1996). Expert failure detection technique for distillation column. *Proceedings of the 22nd International Conference on Industrial Electronics, Control, and Instrumentation, IECON 1996*, v. 3, pp. 1323–1328. doi:10.1109/IECON.1996.570574;
- Elsharkawy, A. (2004). Efficient methods for calculations of compressibility, density and viscosity of natural gases. *Fluid Phase Equilibria*, v. 218, pp. 1–13. doi:10.1016/j.fluid.2003.02.003;

- Embiruçu, M. (1998). Modelagem, Estimacão e Controle em Reatores Industriais de Polimerizacão de Eteno com Catálise Ziegler-Natta Solúvel. Tese de doutorado, UFRJ, Rio de Janeiro, Brasil;
- Fei, S. W. e Zhang, X. B. (2009). Fault diagnosis of power transformer based on support vector machine with genetic algorithm. *Expert Systems with Applications*, v. 36, pp. 11352–11357;
- Fernandes, R. G. (2007). Detecção e Isolamento de Falhas em Sistemas Dinâmicos Baseados em Redes Neurais. Dissertaçao de mestrado, UFRN, Natal, Brasil;
- Filho, D. H. M. (2005). Introduçao ao Processamento e Tratamento do Gás Natural. Rio de Janeiro, Brasil;
- Frank, P. M. (1990). Fault diagnosis in dynamic systems using analytical and knowledge-based redundancy. *Automatica*, v. 26, pp. 459–474;
- Frank, P. M., Ding, S. X. e Marcu, T. (2000). Model-based fault diagnosis in technical processes. *Transactions of the Institute of Measurement and Control*, v. 22, pp. 57–101;
- Frank, P. M. e Köppen-Seliger, B. (1997). Fuzzy logic and neural network applications to fault diagnosis. *International Journal of Approximate Reasoning*, v. 16, pp. 67–88;
- Garcia, C. (2005). Modelagem e Simulaçao. 2a. ed., EDUSP, São Paulo, Brasil;
- Gertler, J. J. (1988). Survey of model based failure detection and isolation in complex plants. *IEEE Control Systems Magazine*, v. 8, pp. 3–11;
- Hagan, M. T. e Menhaj, M. B. (1994). Training feedforward networks with the Marquardt algorithm. *IEEE Transactions on Neural Networks*, pp. 989–993;
- Himmelblau, D. M. (1978). Fault detection and diagnosis in chemical and petrochemical processes. *Elsevier*, Amsterdam, Netherlands;
- IEA (2012). World Energy Outlook 2012. Paris, France;
- Isermann, R. (1997). Supervision, fault-detection and fault-diagnosis methods—an introduction. *Control Engineering Practice*, v. 5, pp. 639–652;

- Isermann, R. (2006). Fault-diagnosis systems, an introduction from fault detection to fault tolerance. *Springer*, Berlin, Germany;
- Isermann, R. e Ballé, P. (1997). Trends in the application of model-based fault detection and diagnosis of technical processes. *Control Engineering Practice*, v. 5, pp. 709–719;
- ISO and IEC (1993). Information technology – Vocabulary – Part 1: Fundamental terms. ISO/IEC 2382-1, *International Organization for Standardization (ISO) Standard*, Genève, Switzerland;
- Invensys (2012). Dynsim Simulation Suite User Guide. Lake Forest, USA;
- Jiang, Q. e Yan, X. (2012). Chemical processes monitoring based on weighted principal component analysis and its application. *Chemometrics and Intelligent Laboratory Systems*, v. 119, pp. 11–20. doi:10.1016/j.chemolab.2012.09.002;
- Jones, H. L. (1973). Failure detection in linear systems. MIT, Massachusetts, USA;
- Khan, M. R. (1998). Sensors' FDD by Quadruple and Modified ART-1 ANNs. *Proceedings of IEEE International Joint Conference on Neural Networks*, Anchorage, pp. 262 – 265;
- Kister, H. Z. (2003). What Caused Tower Malfunctions in the Last 50 Years? *Chemical Engineering Research and Design*, v. 81, pp. 5–26. doi: 10.1205/026387603321158159;
- Kramer, M. A. e Leonard, J. A. (1990). Diagnosis using networks-analysis and criticism. *Computers and Chemical Engineering*, v. 14, pp. 1323–1338;
- Kusiak, A., e Song, Z. (2009). Sensor Fault Detection in Power Plants. *Journal of Energy Engineering*, v. 135, pp. 127–137;
- Lau, C. K., Ghosh, K., Hussain, M. A. e Hassan, C. R. (2013). Fault diagnosis of Tennessee Eastman process with multi-scale PCA and ANFIS. *Chemometrics and Intelligent Laboratory Systems*, v. 120, pp. 1–14. doi:10.1016/j.chemolab.2012.10.005;
- Lee, C., Choi, S. W. e Lee, I. B. (2006). Variable reconstruction and sensor fault identification using canonical variate analysis. *Journal of Process Control*, v. 16, pp. 747–761;

- Li, C.-C. e Jeng, J.-C. (2010). Multiple sensor fault diagnosis for dynamic processes. *ISA Transactions*, v. 49, pp. 415–432. doi: 10.1016/j.isatra.2010.05.001;
- Li, L. e Zhou, D. (2004). Fast and robust fault diagnosis for a class of nonlinear systems : detectability analysis, *Computers & Chemical Engineering*, v. 28, pp. 2635–2646. doi:10.1016/j.compchemeng.2004.07.023;
- Liu, K. W., Lim, W. K., Ho, K. C., Tan, R., Srinivasan, A. e Tay, Y. X. X. (2003). On-line fault detection and diagnosis of a refinery process. *5th IFAC Symposium on Fault Detection, Supervision and Safety of Technical Processes*, Washington D.C.;
- MathWorks (2013a). Simulink: Getting Started Guide. Natick, USA;
- MathWorks (2013b). Developing S-Functions. Natick, USA;
- Mendonça, E. S.; Souza Jr., M. B.; Campos, M. C. M. M. (2009). Desenvolvimento de ferramentas de apoio à operação na tomada de decisões em unidades de recuperação de líquido de gás natural. *Petro & Química*, v. 313, pp. 68 - 72;
- Meza, E. B. M., Souza, J. C. S. de, Schilling, M. T. e Coutto Filho, M. B. do (2006). Utilização de um modelo *neuro-fuzzy* para a localização de defeitos em sistemas de potência. *Sba: Controle & Automação Sociedade Brasileira de Automatica*, v. 17, pp. 103–114;
- Miyoshi, S. C., Monte, T., Bendia, R. M., Souza Jr., M. B.; Secchi, A. R.; Optimal Operation of a Three-Phase Separator to Minimize Severe Slugs Effects in Offshore Oil Platforms. In: *International Conference on Engineering Optimization (EngOpt)*, 3, 2012, Rio de Janeiro, Book of Abstracts, pp. 63;
- MME (2012). Plano Decenal de Expansão de Energia 2021. Brasília, Brasil;
- Nasrifar, K. e Bolland, O. (2006). Prediction of thermodynamic properties of natural gas mixtures using 10 equations of state including a new cubic two-constant equation of state. *Journal of Petroleum Science and Engineering*, v. 51, pp. 253–266. doi:10.1016/j.petrol.2006.01.004;
- Nguyen, D. e Widrow, B. (1990). Improving the learning speed of 2-layer neural networks by choosing initial values of the adaptive weights. *International Joint Conference on Neural Networks*, pp. 21–26;

- Olunloyo, V. O. S., Ajofoyinbo, A. M. e Badiru, A. B. (2004). Neurofuzzy mathematical model for monitoring flow parameters of natural gas. *Applied Mathematics and Computation*, v. 149, pp. 747–770. doi: 10.1016/S0096-3003(03)00177-2;
- Ozyurt, B. e Kandel, A. (1996). A hybrid hierarchical neural network-fuzzy expert system approach to chemical process fault diagnosis. *Fuzzy Sets and Systems*, v. 83, pp. 11–25;
- Palma, L. F. F. B. (2006). Fault detection, diagnosis and fault tolerance approaches in dynamic systems based on black-box models. Tese de Doutorado, UNL, Lisboa, Portugal;
- Palma, L. F. F. B., Silva, R. N. e Coito, F. V. (2002). Metodologia Híbrida de Detecção e Diagnóstico de Falhas em Tempo-Real. *Conferência Científica e Tecnológica em Engenharia*, Lisboa, pp. 1–7;
- Patton, R. J. (1993). Robustness issues in fault-tolerant control. *Proceedings of IEE Colloquium on Fault Diagnosis and Control System Reconfiguration*, London, England, pp. 1–125;
- Perla, R., Mukhopadhyay, S. e Samanta, A. N. (2004). Sensor fault detection and isolation using artificial neural networks. *Proceedings of IEEE Region 10 Conference (TENCON)*, Chiang Mai, Thailand, pp. 676–679;
- Perlingeiro, C. A. G. (2005). Engenharia de Processos: Análise, Simulação, Otimização e Síntese de Processos Químicos, 1a ed., *Blucher*, São Paulo, Brasil;
- Pierri, F., Pavigianiti, G., Caccavale, F. e Mattei, M. (2008). Observer-based sensor fault detection and isolation for chemical batch reactors. *Engineering Applications of Artificial Intelligence*, v. 21, pp. 1204–1216. doi:10.1016/j.engappai.2008.02.002;
- Ploix, J. L. e Dreyfus, G. (1997). Early fault detection in a distillation column : an industrial application of knowledge-based neural modelling. In: *Neural Networks: Best Practice in Europe*, 1997, pp. 21–31;
- PSE (2013). gPROMS. Disponível em: [<http://www.psenterprise.com/gproms.html>]. Acessado em Junho de 2013;

- Qin, S. J. e Li, W. H. (1999). Detection, identification, and reconstruction of faulty sensors with maximized sensitivity. *AIChE Journal*, v. 45, pp. 1963–1976;
- Qin, S. J. e Li, W. H. (2001). Detection and identification of faulty sensors in dynamic processes. *AIChE Journal*, v. 47, pp. 1581–1593;
- Raich, A. e Çinar, A. (1996). Statistical process monitoring and disturbance diagnosis in multivariable continuous processes. *AIChE Journal*, v. 42, pp. 995–1009;
- Ripley, B. D. (1996). Pattern recognition and neural networks. *Cambridge University Press*, Cambridge, United Kingdom;
- Rivera, M. H. M. (2007). Diagnóstico de Falhas em Sistemas a Eventos Discretos: Uma Proposta de Aplicação em Processos de Separação Óleo-Gás. Dissertação de Mestrado, UFRJ, Rio de Janeiro, Brasil;
- Ruiz, D., Nougues, J. M. e Puigjaner, L. (2001). Fault diagnosis support system for complex chemical plants. *Computers & Chemical Engineering*, v. 25, pp. 151–160. doi: 10.1016/S0098-1354(00)00638-4;
- Sartori, I. (2012). Uma Abordagem de Desenvolvimento de Sistemas de Detecção e Diagnóstico de Falhas Baseada em Estudos Prévios de Confiabilidade e sua Aplicação ao Processamento Industrial de Gás Natural. Tese de Doutorado, UFBA, Salvador, Brasil;
- Sartori, I., Amaro, C. de A., Souza Júnior, M. B. de e Embiruçu, M. (2012). Detecção, Diagnóstico e Correção de Falhas: Uma Proposição Consistente de Definições e Terminologias. *Ciência & Engenharia*, v. 21, pp. 29 – 34;
- Sharma, R., Singh, K., Singhal, D. e Ghosh, R. (2004). Neural network applications for detecting process faults in packed towers. *Chemical Engineering and Processing: Process Intensification*, v. 43, pp. 841–847. doi: 10.1016/S0255-2701(03)00103;
- Soares, R. de P. (2007). EMSO Manual. Porto Alegre, RS;
- Soares, R. de P. e Secchi, A. R. (2003). EMSO: A New Environment for Modelling, Simulation and Optimisation. *ESCAPE 13th*, v. 1, pp. 947–952;

- Souza Júnior, M. B. (1993). Redes neuronais multicamadas aplicadas a modelagem e controle de processos químicos. Tese de Doutorado, UFRJ, Rio de Janeiro, Brasil;
- Staudt, P. B., Pelegrini Soares, R. e Secchi, A. R. (2007). Dynamic simulation of reactive distillation processes to predict start-up behavior. *8th International IFAC Symposium on Dynamics and Control of Process Systems*, v. 2, pp. 285–290;
- Staudt, P. B (2007). Modelagem e simulação dinâmica de colunas de destilação. Dissertação de Mestrado, UFRGS, Porto Alegre, Brasil;
- UFRGS (2012). Projeto ALSOC. Disponível em: [<http://www.enq.ufrgs.br/trac/alsoc>]. Acessado em Janeiro de 2012;
- Sun, C. K., Uraikul, V., Chan, C. W. e Tontiwachwuthikul, P. (2000). An integrated expert system/operations research approach for the optimization of natural gas pipeline operations. *Engineering Applications of Artificial Intelligence*, v. 13, pp. 465–475;
- Teixeira, A. C. (2000). Detecção e diagnóstico de falhas em sistemas de processos químicos. Importância do conhecimento de estados intermediários de processos dinâmicos. Desenvolvimento de uma metodologia baseada em redes neurais. Tese de Doutorado, UNICAMP, Campinas, Brasil;
- Tian, W., Guo, Q. e Sun, S. (2011). Dynamic simulation based fault detection and diagnosis for distillation column. *Korean Journal of Chemical Engineering*, v. 29, pp. 9–17. doi: 10.1007/s11814-011-0117-2;
- Tinós, R. (1999). Detecção e diagnóstico de falhas em robôs manipuladores via redes neurais artificiais. Dissertação de Mestrado, USP, São Carlos, Brasil;
- Vapnik, V. (1995). The nature of statistical learning theory. *Springer-Verlag*, New York, USA;
- Vaz, C. E. M., Maia, J. L. P. e Santos, W. G. (2008). Tecnologia da Indústria do Gás Natural. 1a. ed., *Blucher*, São Paulo, Brasil;
- Venkatasubramanian, V., Rengaswamy, R., Yin, K. e Kavuri, S. N. (2003a). A review of process fault detection and diagnosis, Part I: Quantitative model-based methods. *Computers & Chemical Engineering*, v. 27, pp. 293–311;

- Venkatasubramanian, V., Rengaswamy, R. e Kavuri, S. N. (2003b). A review of process fault detection and diagnosis Part II: Quantitative model and search strategies. *Computers & Chemical Engineering*, v. 27, pp. 313–326;
- Venkatasubramanian, V., Rengaswamy, R., Kavuri, S. N. e Yin, K. (2003c). A review of process fault detection and diagnosis. Part III. Process history based methods. *Computers & Chemical Engineering*, v. 27, pp. 327–346;
- VRTech (2005). Vrtherm, a software to predict thermodynamic and physical properties of complex mixtures and pure substances. Disponível em: [www.vrtech.com.br]. Acessado em Abril de 2009;
- VRTech (2008). VRTherm: Manual do Usuário;
- Willsky, A. S. (1976). A survey of design methods for failure detection in dynamic systems. *Automatica*, v. 12, pp. 601–611;
- WS (2011). Web of Science (WS). Disponível em: [http://www.isiknowledge.com]. Acessado entre Janeiro e Fevereiro de 2011;
- Xu, X., Hines, J. W. e Uhrig, R. E. (1999). Sensor Validation and Fault Detection Using Neural Networks. *Proceedings of Maintenance and Reliability Conf. (MARCON)*, Gatlinburg, United States of America, pp. 1–9;
- Yee, M. W. e Ibrahim, K. A. (2003). Fault detection for distillation column using multivariate statistical process control (MSPC). *Symposium of Malaysian Chemical Engineers (SOMChE)*, Penang, Malaysia, pp. 29–30.

UFBA
UNIVERSIDADE FEDERAL DA BAHIA
ESCOLA POLITÉCNICA

PROGRAMA DE PÓS GRADUAÇÃO EM ENGENHARIA INDUSTRIAL - PEI

Rua Aristides Novis, 02, 6º andar, Federação, Salvador BA
CEP: 40.210-630
Telefone: (71) 3283-9800
E-mail: pei@ufba.br
Home page: <http://www.pei.ufba.br>

