



UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
ESCOLA DE ENGENHARIA
DEPARTAMENTO DE ENGENHARIA QUÍMICA
ENG07053 - TRABALHO DE DIPLOMAÇÃO EM ENGENHARIA
QUÍMICA



Proposição de uma Metodologia de Alarmes Preditivos Baseada em Redes Neurais

Autor: Tadeu Mezacasa Forest

Orientador: Marcelo Farenzena

Porto Alegre, julho de 2013

Sumário

Sumário	iii
Agradecimentos	iv
Resumo	v
Lista de Figuras	vi
Lista de Tabelas	vii
Lista de Abreviaturas e Siglas	viii
1 Introdução	1
2 Revisão Bibliográfica	3
2.1 Gerenciamento de Alarmes	3
2.1.1 Alarmes	3
2.1.2 A problemática dos alarmes	3
2.1.3 Ciclo de vida do gerenciamento de alarmes	4
2.1.4 Etapas do ciclo de gerenciamento de alarmes	4
2.1.5 Gerenciamento de Mudanças nos sistemas de alarmes	6
2.2 Alarmes Preditivos	6
2.2.1 Monitoramento Preditivo de Processos	6
2.2.2 Gerenciamento preditivo de alarmes	7
3 Metodologia	10
3.1 Redes Neurais Artificiais	10
3.2 Sistema de alarmes preditivo baseado em redes neurais artificiais	13
4 Estudo de Caso: Coluna Despropanizadora	16
4.1 Descrição da Unidade	16
4.2 Construção dos modelos	17
5 Resultados	19
6 Conclusões e Trabalhos Futuros	26
7 Referências	28

Agradecimentos

Agradeço ao professor Marcelo Farenzena pelos ensinamentos e paciência e principalmente pela amizade e parceria demonstrados ao longo dos últimos anos da minha graduação.

Agradeço à todos os meus familiares e amigos que contribuíram de algum modo para a realização deste trabalho e para a conclusão deste curso.

Resumo

A operação estável e segura de sistemas industriais complexos é um dos mais importantes campos de pesquisa e desenvolvimento da engenharia química. Sistemas de alarmes devem dar suporte ao operador para que as variáveis mais importantes e críticas recebam sua devida atenção. A ineficiência de um sistema de alarmes é um agravante de distúrbios de processo, causador de perdas financeiras, gerador de impactos ambientais ou até mesmo causa raiz de acidentes de processo. Neste trabalho é proposta uma metodologia para um sistema de alarmes baseada em redes neurais artificiais (RNAs) que oferece aos operadores informações antecipadas sobre a atuação de alarmes. Essa informação é construída primeiramente através da simulação computacional dos efeitos dos distúrbios no processo. O segundo passo é reconhecer padrões de distúrbios através do uso das RNAs para obter uma predição do valor de variáveis críticas ao longo do tempo. O bom desempenho que as RNAs possuem no reconhecimento de padrões e na aproximação de funções não-lineares as tornam muito atrativas no campo de predição de alarmes. A metodologia proposta foi aplicada em um estudo de caso de uma coluna de destilação da unidade despropanizadora. As redes neurais configuradas desempenharam bem a sua função de prever tanto a atuação dos alarmes como o tempo desde a aplicação do distúrbio até a transposição do limite de alarme. O bom desempenho foi demonstrado através de métricas como, erro quadrático médio, erro percentual, coeficiente de regressão e matrizes de confusão. As RNAs se mostraram capazes de servir de base para um sistema de predição de alarmes em uma planta de processo real.

Lista de Figuras

Figura 2.1: Fluxograma do ciclo de vida do gerenciamento de alarmes (adaptado de Dunn <i>et al.</i> , 2005).....	6
Figura 2.2: Panorama geral de diagnóstico de falha em um processo (adaptado de Venkatasubramanian <i>et al.</i> , 2003)	7
Figura 3.1: Esquema de modelo artificial de neurônio (adaptado de HOSKINS <i>et al.</i> ,1988)	11
Figura 3.2: Fluxograma simplificado do algoritmo proposto.	14
Figura 3.3: Fluxograma detalhado do algoritmo proposto.	14
Figura 4.1: Representação esquemática da coluna despropanizadora estudada.	16
Figura 4.2: Fluxograma da coluna despropanizadora em <i>Aspen Dynamics</i>	18
Figura 5.1: Matrizes de confusão para as redes neurais de alarmes de fator de inundação alto (a) e muito alto (b).....	22
Figura 5.2: Matrizes de confusão para as redes neurais de alarmes de contaminação da corrente de fundo alto (a) e muito alto (b).	23
Figura 5.3: Matrizes de confusão para as redes neurais de alarmes de contaminação da corrente de topo alto (a) e muito alto (b).	23

Lista de Tabelas

Tabela 3.1: Definições de arquiteturas de rede.	11
Tabela 4.1: Parâmetros dos controladores de composição de topo e fundo.	18
Tabela 5.1: Variáveis escolhidas para o conjunto de entrada das redes neurais.	20
Tabela 5.2: Resumo dos alarmes monitorados e seus limites.	20
Tabela 5.3: Número total de pontos alarmados.	21
Tabela 5.4: Métricas de desempenho obtidos para as redes neurais de alarmes de fator de inundação alto e muito alto.	21
Tabela 5.5: Métricas de desempenho obtidos para as redes neurais de alarmes de contaminação da corrente de fundo alto e muito alto.	21
Tabela 5.6: Métricas de desempenho obtidos para as redes neurais de alarmes de contaminação da corrente de topo alto e muito alto.	22
Tabela 5.7: Métricas de desempenho obtidas para as redes neurais para o tempo de atuação de alarmes do fator de inundação alto e muito alto.	24
Tabela 5.8: Métricas de desempenho obtidas para as redes neurais para o tempo de atuação de alarmes de contaminação da corrente de fundo alto e muito alto.	24
Tabela 5.9: Métricas de desempenho obtidas para as redes neurais para o tempo de atuação de alarmes de contaminação do topo alto e muito alto.	25

Lista de Abreviaturas e Siglas

C_3^- – Corrente de topo da coluna despropanizadora rica nas frações de propano e componentes mais leves

C_4^+ – Corrente de fundo da coluna despropanizadora rica nas frações de butano e componentes mais pesados.

R – Coeficiente de Regressão.

%E – Erro Percentual.

GLP – Gás Liquefeito de Petróleo.

NNTool – Neural Network Toolbox.

RNA – Redes Neurais Artificiais.

1 Introdução

O termo alarme pode ser definido como uma notificação que tem o objetivo de atrair a atenção do operador de painel para uma situação que requer uma avaliação ou ação em um determinado tempo. O alarme deve dar suporte ao operador para que as questões mais importantes ou críticas recebam sua devida atenção. O operador é alertado de modo a prevenir ou mitigar um distúrbio de processo ou um mau funcionamento de um equipamento.

Um sistema de alarmes ineficiente é usualmente indicado como um fator agravante de distúrbios de processo, causador de perdas devido a produto fora de especificação, gerador de resíduos e emissões e até mesmo incidentes e sérios acidentes industriais.

O gerenciamento de alarmes estabelece um plano para gerenciar o ciclo de vida dos sistemas de alarmes presentes nos sistemas de controle de forma a possibilitar o acompanhamento, análise e melhoria contínua do seu desempenho. Essa ferramenta deve ser aplicada para extrair as informações necessárias sobre os cenários críticos da planta de processo para projetar ou melhorar sistemas de segurança. Um gerenciamento de alarmes bem executado resulta em um aumento de segurança e confiabilidade do processo.

As plantas químicas atuais são construídas para possuírem um grande número de operações unitárias integradas e interligadas de modo a aperfeiçoar a capacidade de produção, aumentar a conversão de matéria-prima em produto, reduzir os desperdícios de insumos e minimizar os impactos ambientais e a geração de resíduos e emissões. Quando um distúrbio de processo ocorre, os sistemas de automação alertam os operadores através da atuação de alarmes que ajudam a orientá-los a levar a planta para um novo estado seguro e estável. No entanto, como os sistemas são altamente interligados muitos alarmes simultâneos podem ocorrer durante um período de situação anormal de operação, o que pode levar a uma inundação de alarmes.

Essa inundação de alarmes no painel de operação causa uma confusão entre os operadores que, em uma situação de anormalidade do processo, devem diagnosticar e corrigir o distúrbio antes que ele se desenvolva e acabe se agravando. Quando esse distúrbio não pode ser identificado, devido à quantidade de variáveis alarmando em um mesmo momento, o operador é forçado a ativar o sistema de parada de emergência da unidade, o que resulta em uma perda considerável de produtividade.

As consequências de um alarme não corrigido geralmente pioram em função do tempo. Sendo assim, quanto menos tempo um operador possui para responder a um alerta mais prioritário este alerta deve ser. O gerenciamento preditivo de alarmes é uma ferramenta importante, visto que a capacidade do operador responder a um alarme de forma eficiente em um determinado período de tempo determina a chance de prevenir danos ou perdas maiores no processo.

Metodologias preditivas, tais como extrapolação linear, filtro Kalman e análise de sistema de equações podem ser usadas para prever estados futuros de uma planta de processo. Esses sistemas avançados de monitoramento e supervisão visam minimizar as chances de erro do operador e aumentar a segurança e a confiabilidade do processo através da detecção antecipada de falhas e maus funcionamentos.

O objetivo deste trabalho é propor um sistema de alarmes baseado em redes neurais que oferece aos operadores informações antecipadas sobre alarmes que podem ocorrer dentro de uma janela de tempo. Essa informação é construída primeiramente através da simulação computacional dos efeitos dos distúrbios na condição da planta de processo. O segundo passo é reconhecer padrões de distúrbios através do uso de redes neurais artificiais para obter uma predição do valor de variáveis críticas ao longo do tempo. Desta forma este sistema permite aos operadores adotarem uma postura mais proativa na gestão dos alarmes durante uma situação anormal ou durante uma inundação de alarmes que pode ocorrer durante uma emergência.

A metodologia proposta foi aplicada em um estudo de caso de uma coluna de destilação da unidade despropanizadora responsável por separar uma corrente de GLP (Gás Liquefeito de Petróleo) em outras duas correntes: uma de topo rica nas frações de propano e mais leves (C_3^-) e uma corrente de fundo rica em butano e mais pesados (C_4^+). Esta torre é um elemento crítico na cadeia produtiva de propeno e do corte C_4^+ pois ela é a primeira etapa de separação do GLP. Quaisquer descontroles que ocorrerem na composição de topo e fundo dessa unidade irão levar a perdas de produção ou qualidade nos sistemas subsequentes.

O trabalho está dividido em seis capítulos, com a seguinte estrutura: no capítulo 2 é feita uma revisão bibliográfica sobre gerenciamento de alarmes e sobre as metodologias de alarmes preditivos presentes na literatura. No capítulo 3 a metodologia proposta é descrita e o algoritmo de resolução é apresentado. No capítulo 4 é feita uma descrição da unidade estudada e as particularidades sobre a construção do modelo são apresentadas. No capítulo 5 são apresentados os resultados do desempenho das redes neurais. Por último, no capítulo 6, são expostas as conclusões deste trabalho e sugestões para estudos futuros.

2 Revisão Bibliográfica

Neste capítulo será feita uma revisão sobre gerenciamento de alarmes e alarmes preditivos.

2.1 Gerenciamento de Alarmes

2.1.1 Alarmes

Segundo a norma ANSI/ISA-18.2-2009, alarme é um sinal audível e/ou visível indicativo do mau funcionamento de um equipamento ou processo ou condição anormal que requer uma resposta. Portanto, o alarme deve ser audível e visualmente claro para o operador. Ele também deve requerer um tempo adequado para o operador tomar a ação necessária. Isso implica principalmente que o projeto de um sistema de alarmes deve levar fortemente em conta a dinâmica do processo.

A norma ANSI/ISA-18.2-2009 recomenda que para um alarme ser considerado bem configurado ele deve ter um valor operacional significativo e sempre deve demandar uma resposta do operador, ou seja, ele não deve ser ignorado. O alarme deve ser oportuno, não pode ocorrer de modo tão antecipado, que não requeira nenhuma ação imediata do operador, nem muito tardio, de forma que o operado já não tem mais tempo de corrigir o problema. A importância também é uma característica relevante, pois ela define a significância do problema. Ela é crucial quando se precisa priorizar o alarme que deve ser processado primeiramente quando vários alarmes atuam ao mesmo tempo, por exemplo, em uma situação crítica de emergência. A mensagem que o alarme passa deve ser de fácil e rápido entendimento, auxiliando o operador a identificar o problema e a tomar a ação apropriada.

Hollender (2010) observa do ponto de vista cronológico a problemática dos alarmes. Historicamente, quando as plantas de processo possuíam painéis analógicos de controle, inserir novos alarmes possuía um alto custo associado. A quantidade de alarmes era limitada pelo custo e pela disponibilidade de espaço físico no painel, já que o alarme normalmente era uma luz piscando associado a um sinal sonoro. Portanto, a existência de cada alarme era bem justificada e avaliada. Com a chegada dos sistemas de controle digitais distribuídos, a situação se tornou totalmente diferente, já que, como os alarmes são apresentados em uma interface digital gráfica, o sistema possui uma capacidade virtualmente ilimitada para comportá-los. Além disso, como esse tipo de sistema digital consiste essencialmente de um ou vários softwares, não há um custo associado para inserção de alarmes, pois não há necessidade de justificativa, cabeamento ou tubulação já que a maioria dos sinais que chegam aos sistemas de controle digital distribuído possuem alarmes configurados apenas esperando que sejam habilitados.

2.1.2 A problemática dos alarmes

Neste contexto, sem ter um plano de configuração definido, diversos alarmes foram criados e uma inundação de alarmes nos sistemas de controle se tornou algo recorrente na indústria de processos. Alarmes acionados quase que continuamente mesmo com o processo operando em um regime estável eram o cenário mais comum na indústria. O operador já não era capaz de entender e responder adequadamente aos avisos no painel. Esse cenário se agrava durante um distúrbio de processo, durante o qual aumenta consideravelmente o número de alarmes que chegam até o operador, tornando o sistema ineficiente, além de perigoso. Segundo Beebe *et al.* (2013) muitas investigações de

incidentes citam inundações de alarmes como sendo uma causa significativa que contribuiu para que diversos acidentes ocorressem. Uma inundação de alarmes é definida pela norma internacional ANSI/ISA-18.2-2009 como sendo dez ou mais alarmes anunciados em um período de dez minutos por operador. A norma internacional EEMUA, Publication 191 estipula um máximo de seis alarmes por hora por operador como sendo um valor aceitável.

Os grandes acidentes são apenas a parte mais crítica do problema. Uma gestão de alarmes deficiente pode ser prejudicial para o processo, pois pode mascarar distúrbios comuns de processos, incomodar e distrair operadores no dia-a-dia além de aumentar a depreciação de equipamentos. Um sistema de alarmes sem uma boa gestão conduz a uma situação onde os alarmes são incorretamente configurados. Isso gera um número de sinais irrelevantes e, como consequência principal, os operadores ficam sobrecarregados de informações e podem começar a ignorar os alarmes críticos (EEMUA, Publication 191).

Nas salas de controle da maioria das plantas industriais essa problemática do excesso de alarmes se tornou uma realidade, conforme Hollender (2010). Esse panorama gera muita tensão e estresse para os operadores, principalmente em paradas e partidas de plantas e unidades. Esse estresse leva o operador ao limite da sua resistência física e psicológica trazendo sérios prejuízos ao desempenho profissional além de desgastar a saúde do operador. Um bom sistema de gerenciamento de alarmes permite que os operadores trabalhem em questões mais importantes, tais como a otimização do processo e deixem de se ocupar com os alarmes em excesso.

2.1.3 Ciclo de vida do gerenciamento de alarmes

O gerenciamento de alarmes estabelece um plano para gerenciar o ciclo de vida dos sistemas de alarmes presentes nos sistemas de controle de forma a possibilitar o acompanhamento, análise e melhoria contínua do seu desempenho. Ele tem como principal propósito tornar o sistema eficaz na sua função de passar a informação de algum problema de processo que necessita a atenção do operador de forma clara e concisa. Esse gerenciamento também tem a função de eliminar alarmes inconvenientes ou redundantes, além de promover a correta priorização dos alarmes. O ciclo compreende um conjunto de técnicas para análise, diagnóstico, melhoria e manutenção do sistema de alarmes de forma a atender os requisitos de normas internacionais no que diz respeito á número de alarmes por operador por hora, clareza nas informações do alarme, tempo necessário para resposta, prioridade e relevância. Quando corretamente aplicado e utilizado, o gerenciamento de alarmes traz benefícios em termos de segurança e otimização do processo, bem estar do operador, diminuição do numero de paradas não programadas, entre outros, conforme visto em Stauffer (2012).

2.1.4 Etapas do ciclo de gerenciamento de alarmes

Segundo Stauffer *et al.*(2010) as etapas do processo de gerenciamento de alarmes podem ser alocadas em um ciclo: filosofia, identificação, racionalização, projeto, implementação e treinamento, operação, manutenção, monitoramento, gerenciamento de mudanças e auditorias. A descrição de cada etapa está descrita subseqüentemente.

- Filosofia: descreve como o gerenciamento de alarmes é tratado em uma determinada planta de processo. Abrange as definições e princípios para o

sistema de alarmes e detalhes das práticas de todos os demais estágios do ciclo.

- Identificação: pode ser feita de diferentes formas, tais como, revisão de P&ID's e procedimentos operacionais internos, análises de riscos de processo e investigações de acidentes. Esta etapa serve para identificar os alarmes que serão tratados nos estágios que seguem.
- Racionalização: é o processo de configuração individual dos parâmetros dos alarmes de acordo com os princípios definidos na filosofia de alarmes. Inclui a revisão sistemática de cada alarme configurado. O objetivo desta etapa é otimizar a qualidade e quantidade dos alarmes. Inclui as etapas de classificação e priorização.
- Projeto: inclui a configuração básica dos alarmes, desenho da interface e determinação de métodos avançados. Muitos alarmes inconvenientes podem ser eliminados neste estágio, tais como, os alarmes referentes a sistemas fora de uso esquecidos pela operação ou transmissores redundantes que geram alarmes redundantes.
- Implementação e Treinamento: é a etapa de transição do projeto para a operação. Também inclui o treinamento do operador e testes iniciais dos alarmes.
- Operação: é a etapa na qual o sistema de alarmes está funcionando de fato e, portanto, deve estar reportando condições anormais de processo aos operadores.
- Monitoramento: consiste na coleta, consolidação e análises dos dados de alarmes durante a operação de forma a medir a eficiência do sistema.
- Manutenção: o teste periódico dos alarmes é necessário em qualquer sistema. O instrumento de medição pode necessitar de manutenção ou então outro componente do sistema pode precisar de reparo.

Na Figura 2.1 pode ser visto como estas etapas se interligam formando o ciclo de vida do gerenciamento de alarmes.

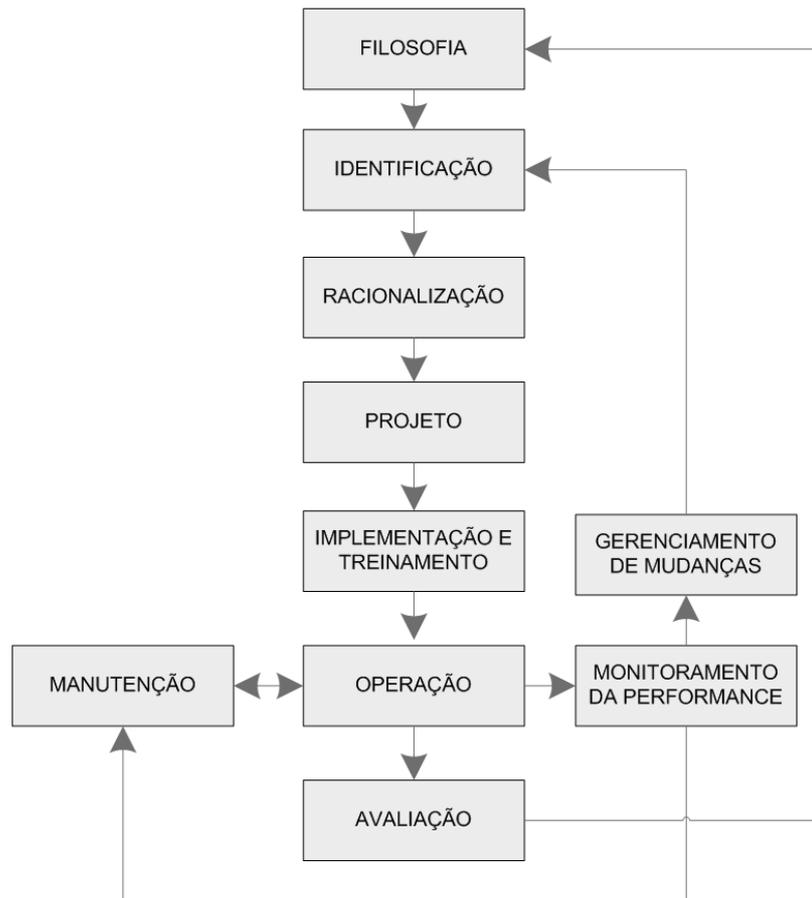


Figura 2.1: Fluxograma do ciclo de vida do gerenciamento de alarmes (adaptado de Dunn *et al.*, 2005)

2.1.5 Gerenciamento de Mudanças nos sistemas de alarmes

O gerenciamento de mudanças é uma boa prática recomendada pela norma ANSI/ISA-18.2-2009. Ela consiste no processo estruturado de avaliação, aprovação e autorização para a realização de adições, modificações e exclusões de alarmes no sistema. Para manter a integridade do sistema de alarmes, os procedimentos de gerenciamento de mudanças devem ser efetivos. Devido à facilidade que os sistemas digitais possuem de se inserir novos alarmes, deve-se estabelecer regras de documentação e avaliação de quaisquer mudanças que sejam feitas, tais como, mudanças de limites dos alarmes, criação ou exclusão de alarmes e mudanças no tipo, descrição e interface gráfica.

2.2 Alarmes Preditivos

2.2.1 Monitoramento Preditivo de Processos

O monitoramento preditivo de processos vem sendo crescentemente estudado devido à demanda atual por processos mais seguros e confiáveis. O uso de métodos computacionais permite aplicar metodologias que resultam em uma detecção antecipada de uma falha de processo. Em Isermann (1984) um panorama sobre o monitoramento de plantas de processo é apresentado. Anteriormente aos métodos preditivos, uma falha técnica no processo somente era reconhecida quando os valores limites do sinal medido eram transgredidos. Com o auxílio de modelos de processo, e de métodos de estimativa e decisão, é possível também realizar a predição de uma variável, bem como estimar variáveis que não podem ser medidas diretamente.

2.2.2 Gerenciamento preditivo de alarmes

Kim *et al.* (1990) aponta que capacidade de gerenciar um distúrbio de processo é uma das mais importantes e difíceis tarefas que os operadores devem realizar nas salas de controles das plantas industriais. Essa dificuldade está no fato de que o diagnóstico da causa raiz do problema excede a capacidade cognitiva do operador. O autor explica que um distúrbio em uma planta de processo contínua é um fenômeno dinâmico, pois ele se propaga com o tempo. A condição da planta se torna cada vez mais perturbada na medida em que o distúrbio se propaga pelo sistema, caso uma detecção e correção antecipada não sejam feitas. O quanto antes esta condição instável da planta seja detectada e corrigida, maiores são as chances da estabilidade do processo ser retomada. Essa estabilização do processo via diagnóstico antecipado da perturbação aumenta a produtividade da planta, bem como sua segurança evitando que os sistemas de intertravamentos e segurança da planta atuem.

Apesar dos avanços no uso de modelos para detectar desvios de processo antecipadamente, a tarefa de responder adequadamente a um evento anormal ainda está nas mãos do operador. Como visto em Venkatasubramanian *et al.* (2003) essa resposta adequada inclui reconhecer um evento anormal de processo a tempo, fazer um diagnóstico sobre sua causa raiz e tomar decisões e ações adequadas para trazer o processo de volta a seu estado normal de operação. Porém, essa resposta nem sempre é adequada já que os operadores nem sempre são capazes de responder a tempo, por estarem sobrecarregados com outras tarefas, ou até mesmo por não terem o conhecimento do processo e experiência na área necessárias para tomar as ações que evitariam o evento. Na Figura 2.2 vê-se que o diagnóstico do operador pode ser complicado, pois um evento anormal no processo pode ser proveniente de diversas fontes de distúrbios, que incluem falha de controladores, sensores ou atuadores além das falhas estruturais e os distúrbios de processo.

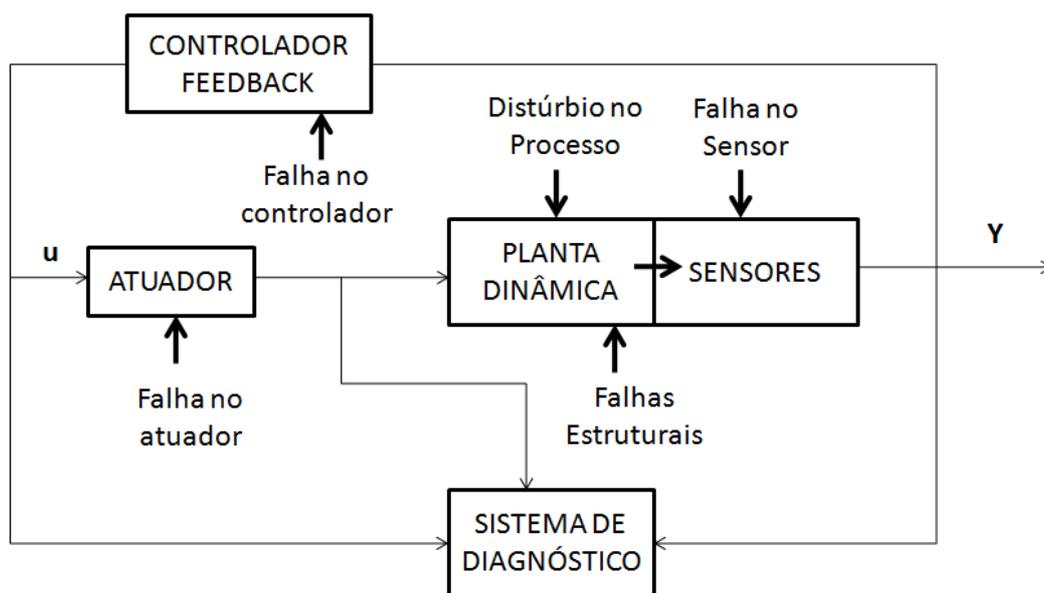


Figura 2.2: Panorama geral de diagnóstico de falha em um processo (adaptado de Venkatasubramanian *et al.*, 2003)

Varga *et al.* (2010) esclarece que o gerenciamento preditivo de alarmes, portanto, deve ser capaz de, não somente detectar uma situação anormal de processo

antecipadamente, mas também deve ser capaz de dar apoio para o operador agir de forma a garantir a segurança e estabilidade do processo. Como certos ajustes demandam um tempo até que impactem no processo, um alarme preditivo também deve ser capaz de definir em qual instante de tempo cada ação deve ser tomada.

Na literatura existem poucos trabalhos que propõem metodologias com uma abordagem preditiva para sistemas de alarmes.

Em Goto *et al.* (1995) um sistema de alarmes inteligente baseado em lógica Fuzzy é proposto. Tal abordagem foi seguida para criação de um modelo para predição de situações anormais, a partir da extração do conhecimento dos operadores. No artigo em questão, o método foi aplicado para predizer anormalidades em um sistema de secagem de uma planta. O reconhecimento da condição da planta é feito através da conversão das variáveis de estado da planta em uma linguagem que possa ser usada nos conjuntos de dados Fuzzy. O método é capaz de notificar antecipadamente uma anormalidade em potencial nos casos em que o operador não pode decidir claramente se a planta está em uma condição normal ou não.

No trabalho de Juricek *et al.* (2001) um método de detecção antecipada de situações anormais de processo é proposto. Nesta abordagem, as predições são obtidas com base em um filtro de Kalman modificado e são usadas para determinar quando o processo irá violar um limite de emergência. O filtro de Kalman gera uma estimativa para um valor real de uma grandeza medida e valores associados predizendo um valor e a incerteza associada ao valor que foi predito, através do cálculo da média ponderada entre o valor medido e o predito. Para obter essas predições é assumido que se dispõe de um modelo linear preciso, os ruídos estatísticos são conhecidos e os distúrbios que afetam os processos também são bem conhecidos. Uma característica especial deste trabalho é uma avaliação de uma estatística tipo T^2 para realizar uma comparação com o estado real da planta e as predições realizadas. Portanto, este método estatístico fornece uma quantificação da precisão das predições feitas anteriormente. Consequentemente, a validação do que foi assumido e a confiabilidade das predições são avaliadas. Essa verificação permite decidir se as predições futuras realizadas são confiáveis ou não e se poderão ser usadas como base para uma decisão de uma ação de controle. Por exemplo, se uma predição sinalizar uma situação de emergência iminente, mas os valores da estatística T^2 excederem os limites calculados, então a situação prevista deve ser ignorada.

Em Braunstein *et al.* (2009) é proposto um sistema de predição de alarmes para auxiliar a implantação de uma política de manutenção preventiva de equipamentos. Esse sistema é baseado em técnicas estatísticas de árvores de regressão e classificação não supervisionada. A metodologia se baseia no mapeamento dos subconjuntos de sinais de entrada que estão associados a cada alarme, através de métodos de árvores de regressão. Monitorando os sinais adequados, o sistema pode prever as possíveis falhas no processo. Esse sistema é dividido em módulos: extração de médias, fornecimento de unidades e previsão de alarmes. O módulo de extração de médias é responsável pela divisão estrutural das séries temporais das variáveis monitoradas para tentar identificar algum comportamento padrão antes da ocorrência de alarmes. Para isso, se faz uso de árvores de regressão de mínimos quadrados. No módulo de fornecimento de utilidades as séries que foram identificadas como pertinentes ao disparo de um ou vários alarmes, analisadas no módulo anterior, são filtradas permitindo a redução no tamanho do

conjunto de dados que será inserido na próxima etapa. Os dados pertinentes serão utilizados no módulo seguinte de previsão de alarmes. Nesse módulo as características das condições normais e anormais da planta são identificadas através do uso de um classificador não supervisionado *k-means*. Desta forma consegue reconhecer os padrões de comportamento normal e anormal de operação.

Em Varga *et al.* (2010) é proposto um gerenciamento preditivo de alarmes que visa detectar uma situação perigosa antecipadamente e dar conselhos aos operadores para quais ações devem ser tomadas. A essência da metodologia é a simulação antecipada do efeito dos ajustes de processo feitos pelo operador. Como cada ajuste de processo demanda certo tempo para que seja efetivo na sua função de evitar uma situação perigosa, a metodologia também calcula o tempo exato que cada ação deve ser tomada para evitar a propagação do distúrbio. Para atingir estes objetivos, foi utilizada uma análise de estabilidade de Lyapunov's no sistema de equações que descreve o sistema. Desta forma é possível prever regiões estáveis e instáveis de operação. Esta informação é então utilizada no gerenciamento preditivo de alarmes.

3 Metodologia

A metodologia proposta tem o objetivo de criar um sistema preditivo de alarmes baseado em redes neurais artificiais capaz de detectar quando um distúrbio em alguma variável medida irá resultar na transposição de um limite de alarme de alguma variável monitorada com um tempo de antecedência. O sistema também deve ser capaz de determinar o tempo desde a ocorrência do distúrbio até a atuação do alarme.

Sendo assim será feita uma breve introdução sobre os fundamentos das redes neurais, bem como da sua importância e capacidade de aplicação para alcançar os objetivos propostos.

3.1 Redes Neurais Artificiais

As redes neurais artificiais (RNA) são técnicas computacionais que se baseiam em um modelo matemático inspirado na estrutura neuronal de organismos inteligentes capazes de adquirir conhecimento através da experiência. Esse tipo de modelo também pode ser chamado de modelo de inferência multidimensional não-linear (Basheer *et al.*, 2000).

Segundo Fausett (1994), o modelo matemático da estrutura neural biológica assume que:

- O processamento de informações ocorre através de muitos pequenos elementos chamados neurônios.
- Sinais são transmitidos através dos neurônios via ligações.
- Cada ligação tem um peso associado, o qual multiplica o sinal transmitido.
- Cada neurônio aplica uma função de ativação (normalmente não-linear) em sua entrada, que é a soma ponderada de todas as entradas, para determinar a sua saída.

O neurônio artificial trabalha de forma similar ao neurônio biológico e seu esquema de funcionamento pode ser visto na Figura 3.3. Ele possui várias entradas (x), que podem ser conectadas com outras unidades, e uma saída. Os sinais de entrada são multiplicados pelos pesos sinápticos (w) que amplificam os sinais recebidos. Esse modelo inclui um valor adicional, o *bias*, que tem a função de favorecer ou limitar a ativação do neurônio artificial. O valor da saída, portanto, depende diretamente do somatório ponderado de todas as entradas. Esse valor de saída pode ser a saída global da rede ou ainda pode alimentar outros neurônios artificiais de uma próxima camada (HOSKINS *et al.*, 1988).

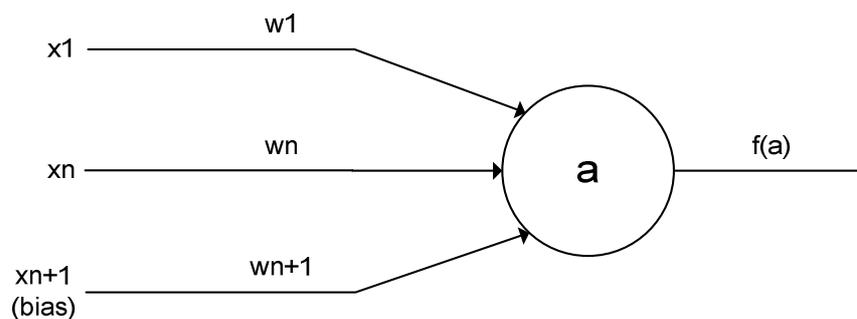


Figura 3.1: Esquema de modelo artificial de neurônio (adaptado de HOSKINS *et al.*,1988)

Uma rede neural é caracterizada primeiramente pelo seu padrão de conexão entre os neurônios, chamado de arquitetura de rede. Também é caracterizada pelo método que ela determina os pesos das conexões, chamado de algoritmo de treinamento e por fim pela sua função de ativação.

Assim como nas redes neurais biológicas, um neurônio sozinho possui capacidade extremamente limitada. As RNAs definem a disposição dos neurônios e suas ligações nas chamadas arquiteturas de redes. Nelas, parâmetros como número de camadas, número de nós de cada camada e tipo de conexões são considerados e podem ser configurados conforme Tabela 3.1.

Tabela 3.1: Definições de arquiteturas de rede.

Número de Camadas	Camada Única: apenas um nó entre a entrada e a saída da rede		Múltiplas Camadas: mais de um neurônio entre a entrada e a saída
Conexões	<i>Feedforward</i> : a saída de um neurônio em uma camada não alimenta outro neurônio da mesma ou de outra camada	<i>Feedback</i> : a saída de um neurônio de uma camada pode alimentar outros neurônios	Auto associativa: todas as conexões são do tipo <i>feedback</i>
Conectividade	Conexão fraca ou parcial		Rede completamente conectada

A função de ativação é responsável por gerar a saída do neurônio a partir dos pesos sinápticos e dos valores de entrada. A função de ativação pode ser linear ou não-linear. Na maioria dos casos, funções não-lineares são utilizadas nas camadas ocultas, pois podem gerar uma gama de valores bem maiores para saída do neurônio podendo assim explorar melhor as vantagens das redes com múltiplas camadas.

O modelo matemático do neurônio, apresentado anteriormente, tem a capacidade de coletar, manipular e armazenar dados de experimentos. O processo de aprendizagem ocorre a partir dos chamados algoritmos matemáticos de aprendizagem. A partir de informações contidas em pares de entrada e saída, chamados de dados de treinamento, contido em um conjunto de dados, as redes neurais artificiais devem generalizar o conhecimento contido nesses dados visando responder adequadamente quando uma entrada que não estava presente no conjunto de dados de treinamento for inserida na

rede. Esse reconhecimento de padrões é alcançado modificando os pesos sinápticos da rede, de forma ordenada.

A cada iteração do treino, a RNA tem seus parâmetros modificados, através da modificação dos pesos sinápticos, com o objetivo de alcançar uma solução mais próxima da desejada, ou seja, com o menor erro. O número de neurônios na camada intermediária da rede é um parâmetro importante. Poucos neurônios levam a um não aprendizado da rede, já muitos neurônios podem levar a um *overfitting* que ocorre quando a rede não é capaz de generalizar o raciocínio para entradas fora do conjunto inicial.

O aprendizado das redes neurais pode ocorrer de duas formas: supervisionada e não supervisionada.

No aprendizado supervisionado, para cada padrão de entrada, a rede tem sua saída corrente comparada com a saída desejada pelo supervisor, que fornece informação sobre a direção do ajuste dos pesos sinápticos. Essa modificação nos pesos objetiva se obter o menor erro entre a saída da rede e a saída desejada.

A grande diferença do aprendizado não supervisionado é que nesse caso, inicialmente, o rótulo de dados não é conhecido, somente os padrões de entrada estão disponíveis para a rede, ao contrário do aprendizado supervisionado, no qual o conjunto de treinamento é composto de pares de entrada e saída. Durante o processo de aprendizado, os padrões de entrada são apresentados continuamente à rede e a existência de regularidades nesses dados possibilita o aprendizado da rede.

Essa capacidade de aprendizado das RNAs faz diminuir a dependência de um conhecimento aprofundado sobre o problema, ou seja, da origem dos dados de entrada ou de saída. O modelo interno criado pelas redes, através do treinamento, é capaz de perceber os padrões dos dados fornecendo uma boa resposta, sem precisar saber a origem dos dados, ou seja, sem saber as equações ou os modelos que geraram os dados de entrada. Portanto, as redes neurais artificiais podem representar de forma eficiente um grupo de funções não-lineares com um grande conjunto de dados de entrada e saída apenas controlando os parâmetros dos pesos sinápticos.

Além da grande eficiência que as redes neurais artificiais possuem no reconhecimento de padrões, elas também possuem a vantagem de processar informações afetadas por ruídos obtendo o mesmo raciocínio correto. Outras características importantes são a robustez, pois a eliminação ou adição de neurônios não afeta significativamente o comportamento global da rede, e a flexibilidade, pois a rede pode ser reajustada facilmente para novas entradas de dados realizando-se apenas mais um processo de aprendizagem.

O problema de reconhecimento de padrões, também chamado de regressão, utilizando RNAs consiste em encontrar uma função que produza estimativas com menores erros dado um conjunto de pares entrada e saída. O objetivo dessa regressão não é memorizar o conjunto de pares de entrada e saída, mas sim antecipar novos pares que não estavam incluídos na amostra inicial de treinamento da rede.

No problema mais simples de regressão utilizando RNAs parte-se de um conjunto de pares entrada (x) e saída (y):

$$C = \{(x, y)\} \quad (3.1)$$

e tem-se como objetivo modelar uma função:

$$f = y(x, w) \quad (3.2)$$

onde w representa os pesos sinápticos da rede. Ao modelar a função, supõe-se uma arquitetura de rede, o que equivale a escolher a família de funções f .

Esta função f deve gerar estimativas que possuam os menores erros possíveis para pares de entrada e saída fora do conjunto C , através do ajuste dos parâmetros da função f .

Por consequência isso possibilita a predição de saídas possíveis para entradas x fora do conjunto de treinamento C . Esta capacidade de reconhecimento de padrões e predição de saídas é o que torna as RNAs extremamente interessantes para o tratamento de dados visando à predição de alarmes.

O desempenho da rede será medido por meio das seguintes métricas:

- Coeficiente de Regressão (R): mede a correlação entre as saídas da rede e os resultados desejados. Valores do coeficiente mais próximos da unidade significam uma boa aproximação e mais próximo de zero uma regressão aleatória.
- Erro Percentual (%E): indica a fração, em porcentagem, das amostras que foram classificadas de modo errado.
- *Mean Squared Error* ou Erro Quadrático Médio (MSE): é o erro resultante do somatório das diferenças entre a saída gerada em relação à entrada (e) elevada ao quadrado, multiplicado pelo inverso do número total de elementos treinados (N).

$$MSE = \frac{1}{N} \sum_{i=1}^N (e_i)^2 \quad (3.3)$$

Além das métricas citadas, também serão apresentadas as matrizes de confusão, também chamadas de matrizes de confiabilidade ou acerto. Nelas se pode observar o número de classificações corretas *versus* as classificações preditas para cada classe. O número de acertos, para cada classe se localiza na diagonal principal da matriz. Os demais elementos representam os erros de classificação.

3.2 Sistema de alarmes preditivo baseado em redes neurais artificiais

Para aplicar a metodologia proposta é preciso seguir os seguintes passos. Primeiramente todo o conhecimento sobre a unidade que a metodologia será aplicada deve ser coletado e um modelo preciso do processo deve ser criado. Através das técnicas de gerenciamento de alarmes os pontos críticos do processo devem ser mapeados e as principais variáveis para o seu funcionamento seguro e estável devem ser registradas. Nesta etapa uma análise dos principais distúrbios que ocorrem no processo estudado também deve ser realizada, pois estas serão as variáveis nas quais serão aplicados as variações para simular os distúrbios e avaliar suas consequências no funcionamento da unidade.

O algoritmo do sistema de alarmes proposto é dividido em duas partes, cada uma com uma rede neural distinta. Na primeira parte é identificado se um distúrbio medido irá resultar na transposição de um limite de alarme, o qual normalmente possui dois níveis, por exemplo, alto e muito alto. Se a resposta for positiva, o algoritmo executa a segunda parte, que consiste na determinação do tempo até a transposição do alarme identificado na etapa anterior. O algoritmo simplificado pode ser visto na Figura 3.2.

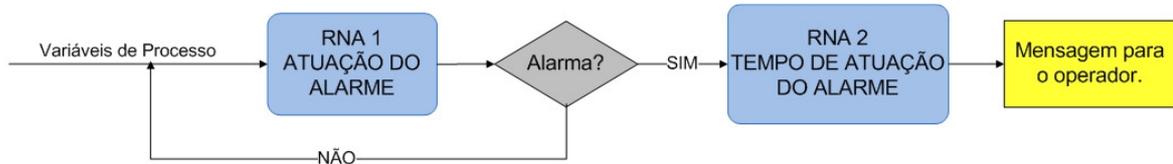


Figura 3.2: Fluxograma simplificado do algoritmo proposto.

Um fluxograma do algoritmo mais detalhado pode ser visto na Figura 3.3.

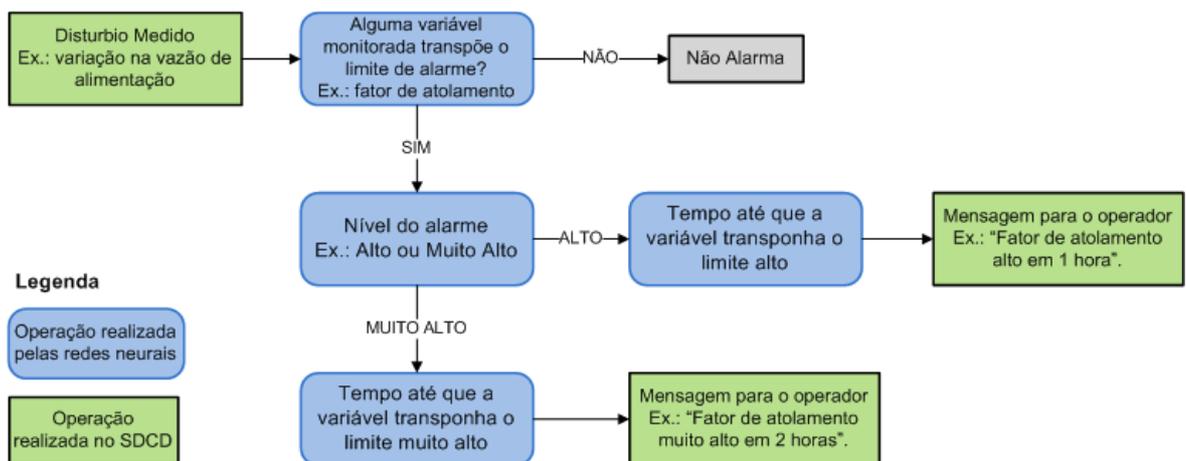


Figura 3.3: Fluxograma detalhado do algoritmo proposto.

Para alcançar este objetivo primeiramente é necessário dispor de um modelo preciso do processo. Como é preciso avaliar a dinâmica da resposta dos distúrbios é necessária que uma simulação dinâmica do processo seja gerada. Para isso foi utilizado, primeiramente o software de simulação dinâmica *Aspen Dynamics*.

Com o modelo implementado neste software, o próximo passo é simular o efeito dos distúrbios nas condições da planta, ou seja, determinar o estado estacionário que cada distúrbio de processo irá resultar. Primeiramente são elencadas as variáveis que mais comumente podem sofrer distúrbios na unidade estudada baseando-se no conhecimento do processo real.

Estes dados coletados vão pertencer ao conjunto de entradas que serão usadas pelas redes neurais, que irão ser capazes de reconhecer padrões de distúrbios e como saída, irão gerar a predição dos alarmes.

As redes neurais foram implementadas utilizando o software matemático Matlab (*Matrix Laboratory*) versão 7.8.0.347 (R2009a). Uma das principais vantagens do software, além da facilidade de escrita e depuração dos códigos, é a sua biblioteca de ferramentas (*toolboxes*) de aplicações específicas, incluindo de Redes Neurais.

O *toolbox* de redes neurais do MATLAB que foi utilizado é o *Neural Network Toolbox* (NNTool) o qual possui uma interface gráfica para facilitar a importação, criação, utilização e exportação dos dados das redes neurais.

Para criação das RNAs no NNTool é preciso definir os padrões de entrada e saída, inicializar a rede, definir os parâmetros de treinamento, treinar a rede e por fim realizar os testes na rede. Os parâmetros de treinamento que devem ser definidos são: número de neurônios na rede, função de ativação e quantidade dos dados que serão utilizados em cada etapa da configuração: treinamento, validação e teste da rede.

Cabe lembrar que a fase de treinamento da rede só ocorre uma vez e não precisa estar ligada com a planta real. As redes são treinadas *offline* o que elimina a necessidade de um simulador em linha com a planta de processo tornando a metodologia mais rápida, barata e confiável. Após o treinamento as redes são conectadas com os sistemas de controle distribuídos para receber os sinais da planta e passam a operar para o teste contínuo de distúrbios.

A comunicação entre as simulações no software *Aspen Dynamics* e o ambiente do Matlab foi feita através de planilhas de Excel. Os resultados das simulações foram extraídos para as planilhas e esses dados foram lidos pelo Matlab através do comando *xlsread*. Com os dados das simulações inseridos no Matlab as entradas e saídas das redes neurais podem ser definidas.

4 Estudo de Caso: Coluna Despropanizadora

4.1 Descrição da Unidade

A coluna despropanizadora é uma torre de destilação que tem o objetivo de separar uma corrente de GLP (Gás Liquefeito de Petróleo), proveniente de uma seção de tratamento químico, em outras duas correntes. A corrente de GLP possui como principais componentes etano, propeno, propano, isobutano, isobuteno e 1-buteno.

A corrente de topo desta coluna é rica nas frações de propano e mais leves (C_3^-). A corrente de fundo é rica em butano e mais pesados (C_4^+).

A despropanizadora é equipada com 42 pratos valvulados e opera continuamente com uma pressão de topo de aproximadamente 16 kgf/cm². Um esquema simplificado da coluna pode ser visto na Figura 4.1.

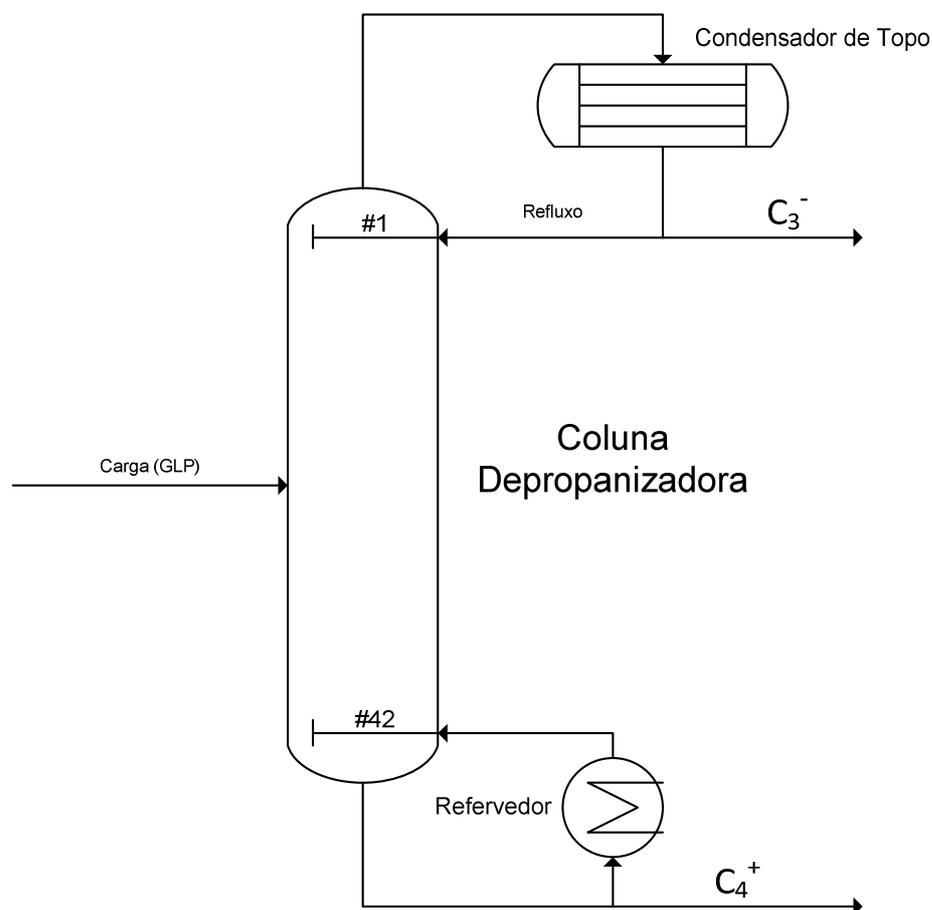


Figura 4.1: Representação esquemática da coluna despropanizadora estudada.

Os vapores de topo são condensados com água de resfriamento e coletados no vaso de refluxo. Parte deste produto coletado no vaso de refluxo retorna para a torre no primeiro prato superior. Esta corrente de refluxo é responsável por controlar a pureza do destilado. A outra parte do fluxo contendo as frações de propano e mais leves é enviada para uma seção de tratamento cáustico para remover principalmente compostos de enxofre.

A quantidade de calor necessária para a operação adequada da torre é fornecida por um refervedor de fundo que opera com vapor de baixa pressão. No fundo é retirada a

fração de butano e mais pesados que é retificada e enviada para armazenamento em esferas.

O controle desta coluna, além de garantir o bom funcionamento hidráulico da coluna, tem o objetivo de ter a menor perda de propeno possível na corrente de fundo e a menor contaminação da corrente de topo por iso-buteno.

Os demais detalhes da coluna e os dados sobre a sua alimentação foram suprimidos por sigilo. Além disso, será usada uma porcentagem dos valores de projeto para as simulações.

4.2 Construção dos modelos

Para gerar os dados necessários para as entradas das redes neurais é imprescindível ter não somente um modelo preciso do processo, mas também um simulador que seja capaz de estimar a trajetória em função do tempo das variáveis de processo durante a operação normal e anormal da unidade. O simulador também deve ser capaz de modelar os sistemas de controle do processo analisado, visto que os sistemas de automação possuem grande influência no controle dos impactos de distúrbios e na estabilidade do processo.

Portanto, para construir um modelo que represente de forma satisfatória o comportamento estático e dinâmico da coluna despropanizadora estudada, foi utilizado o software de simulação *Aspen Plus* para inicialmente avaliar o comportamento da coluna em estado estacionário.

Após a implementação estática, os dados obtidos foram exportados para o software *Aspen Plus Dynamics* onde foram realizadas as simulações dinâmicas possibilitando o estudo dos estados transientes da coluna e da resposta do sistema frente a distúrbios aplicados.

O modelo termodinâmico escolhido para ser utilizado na construção do modelo foi o de Peng-Robson. Este pacote termodinâmico foi escolhido por ser indicado para descrever as propriedades termofísicas de misturas líquidas de hidrocarbonetos.

O comportamento hidráulico do modelo foi definido utilizando dimensões de tamanho de prato, espaçamento entre pratos e diâmetro da coluna comparáveis aos da coluna original. No modelo foi utilizado o tipo de prato valvulado com borbulhadores.

Os controles básicos da coluna, definidos automaticamente pelo software *Aspen Plus Dynamics*, são os de controle de inventário e pressão. O controle de inventário do vaso de fundo é feito através da manipulação da vazão da corrente de fundo. O controle de inventário do vaso de topo é feito através da manipulação da vazão da corrente de destilado. O controle de pressão do topo da coluna é obtido pela manipulação da taxa de calor removida no condensador.

Além dos controles básicos, foram configurados mais dois controladores de composição no topo e no fundo. O controlador de composição no topo foi configurado para manter a vazão molar de propano constante, variando a vazão de refluxo. O controlador de composição no fundo foi configurado de modo a manter constante a vazão molar de isobutano tendo como variável manipulada o calor fornecido no

refervedor. Os controladores foram configurados pelo método de síntese direta e seus parâmetros estão na Tabela 4.1.

Tabela 4.1: Parâmetros dos controladores de composição de topo e fundo.

	Composição de Topo	Composição de Fundo
Ganho – K (%/%)	3,2	2,7
Constante de Tempo – τ (h)	1,5	1,7

O modelo implementado no *Aspen Dynamics* pode ser observado na Figura 4.2.

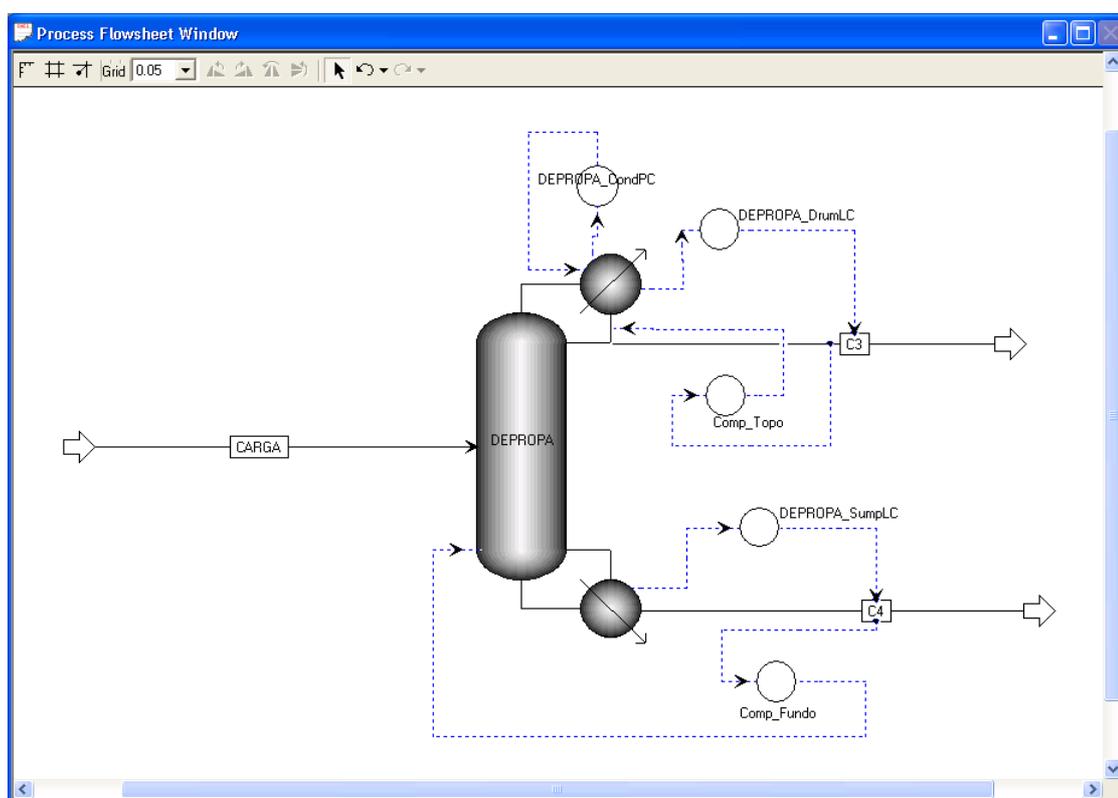


Figura 4.2: Fluxograma da coluna despropanizadora em *Aspen Dynamics*.

As implementações estática e dinâmica dos modelos foram realizadas no GIMSCOP – Grupo de Intensificação, Modelagem, Simulação, Controle e Otimização de Processos do Departamento de Engenharia Química da Universidade Federal do Rio Grande do Sul. Os softwares utilizados foram o *Aspen Plus 7.1*, *Aspen Plus Dynamics 7.1*.

5 Resultados

Na predição de alarmes o objetivo é classificar um conjunto de entrada visando um conjunto de saída conhecido. Esse problema é chamado de problema de reconhecimento de padrões. Com o algoritmo proposto neste trabalho o problema se divide em duas partes.

Na primeira parte, o problema se resume em classificar se um estado da planta implica ou não a transposição dos limites de alarmes de uma variável. Na prática, as entradas da rede serão quatro variáveis monitoras escolhidas e a saída será zero caso o estado da planta definido por essas quatro variáveis não transponha um limite de alarmes e um se ocorrer transposição do limite de alarme.

Na segunda parte, o sistema de redes neurais artificiais tem por objetivo determinar o tempo decorrido desde a aplicação do distúrbio nas variáveis monitoradas até a ocorrência do alarme.

Na fase de treinamento das RNA o conjunto de entradas é dividido, de forma randômica, em três partes, cada uma com uma função específica de configuração:

- Treinamento: os dados desse conjunto são apresentados como entrada da rede durante a fase de treinamento e os parâmetros da rede são ajustados de acordo com os erros baseados neste conjunto. Este conjunto foi definido como 70% dos dados de entrada.
- Validação: esses dados são utilizados para medir a capacidade de generalização da rede e como critério de parada para as iterações do treinamento quando o desempenho da rede se tornar constante. Este conjunto foi definido como 15% dos dados de entrada.
- Teste: esse conjunto de dados não tem efeito no treinamento da rede e, portanto, é utilizado para medir o desempenho da rede durante e após o treinamento. Na prática, estes dados podem ser vistos como a simulação do funcionamento real da rede. Este conjunto foi definido como 15% dos dados de entrada.

Cabe ressaltar que a cada treinamento as redes neurais têm um desempenho final diferente. Isso ocorre devido às condições iniciais dos pesos sinápticos e *bias* e às amostras escolhidas para as etapas de treinamento, validação e teste serem randômicas. Assim, para manter a coerência dos resultados, cada rede neural foi treinada por dez vezes e o melhor desempenho obtido foi apresentado.

Será analisada também a influência do número de neurônios na camada intermediária da rede, visto que este é um parâmetro livre de escolha durante a configuração. Segundo Zhang *et al.* (1998) o método mais comum para determinação do número de neurônios na camada intermediária é via tentativa e erro. Sendo assim, as redes serão testadas para três diferentes números de neurônios intermediários.

Em geral, quanto menor o número de neurônios, maior é a tendência de generalização da rede e mais fácil e rápido é o treinamento. A escolha do número de neurônios se dá sempre visando o menor número de neurônios em que se atinge um desempenho satisfatório para a aplicação que se deseja.

Inicialmente será focada a resolução da primeira parte do algoritmo. Para tanto, as RNAs foram configuradas utilizando o *toolbox* do Matlab chamado de *Neural Network Pattern Recognition Tool*. Esse *toolbox* gera uma interface gráfica que auxilia na seleção dos dados, criação e treinamento das redes e a avaliação do desempenho das mesmas. Nesta parte a avaliação do desempenho das redes se dá através de duas formas: erro quadrático médio (MSE) e das matrizes de confusão.

O *toolbox* utiliza uma rede do tipo *feedforward*, com neurônios intermediários e de saída do tipo tangente sigmoideal que possui uma boa capacidade de classificar dados arbitrários, desde que possuam uma quantidade de neurônios suficiente na sua camada intermediária. O algoritmo de treinamento utilizado é o de *backpropagation*.

As entradas das redes serão definidas como conjuntos de variáveis que descrevem um estado estacionário da planta. Nelas serão aplicadas as variações de modo a simular distúrbios de processo. No total foram simulados 10490 estados estacionários. As variáveis escolhidas para o conjunto de entrada estão mostradas na Tabela 5.1.

Tabela 5.1: Variáveis escolhidas para o conjunto de entrada das redes neurais.

	Vazão de Alimentação total	Vazão molar de propeno na alimentação	Taxa de Destilado	Calor no Refervedor
Limite Inferior	-50%	-10%	-10%	-10%
Limite Superior	+50%	+10%	+10%	+10%
Número de Pontos	14	12	5	10

Os alarmes monitorados são: concentração molar de propeno na corrente de fundo, concentração molar de isobuteno na corrente de topo e o fator de atolamento da coluna. Os limites dos alarmes são apresentados na Tabela 5.2. Para cada nível de alarme será treinada uma rede neural. Portanto, ter-se-ão treinado seis redes neurais nesta etapa.

Tabela 5.2: Resumo dos alarmes monitorados e seus limites.

	Concentração molar de propeno na corrente de fundo (kmol/kmol)	Concentração molar de isobuteno na corrente de topo (kmol/kmol)	Fator de atolamento
Limite Alto	0,01	0,01	0,9
Limite Muito Alto	0,1	0,1	1,00

Para demonstrar o bom desempenho das redes neurais serão utilizados os critérios já citados anteriormente: o erro quadrático médio (MSE), o erro percentual (E%) e as matrizes de confusão.

O número de pontos alarmados está disposto na Tabela 5.3 As métricas de desempenho obtidas para as redes neurais configuradas para a identificação de alarmes

de fator de atolamento alto e muito alto, contaminação da corrente de fundo alto e muito alto e contaminação da corrente de topo alto e muito alto estão na Tabela 5.4, Tabela 5.5: e Tabela 5.6, respectivamente.

Tabela 5.3: Número total de pontos alarmados.

Total de Pontos Alarmados	Concentração molar de propeno na corrente de fundo	Concentração molar de isobuteno na corrente de topo	Fator de atolamento
Limite Alto	7867	6154	1681
Limite Muito Alto	6084	5602	424

Tabela 5.4: Métricas de desempenho obtidos para as redes neurais de alarmes de fator de inundação alto e muito alto.

Número de neurônios na camada intermediária	Fator de Atolamento	Alarme Alto		Alarme Muito Alto	
		MSE	%E	MSE	E%
3	Treinamento	0,0367	4,33	0,00108	0,0408
	Validação	0,0373	4,44	0,00113	0,0
	Teste	0,0410	5,27	0,00115	0,0
6	Treinamento	0,0352	4,44	0,00141	0,0272
	Validação	0,0335	4,00	0,00178	0,0
	Teste	0,0421	5,14	0,00203	0,127
10	Treinamento	0,0257	2,96	0,000165	0,0
	Validação	0,0223	2,73	0,000726	0,063
	Teste	0,0246	2,85	0,000169	0,190

Tabela 5.5: Métricas de desempenho obtidos para as redes neurais de alarmes de contaminação da corrente de fundo alto e muito alto.

Número de neurônios na camada intermediária	Contaminação da Corrente de Fundo	Alarme Alto		Alarme Muito Alto	
		MSE	%E	MSE	E%
3	Treinamento	0,00440	0,403	0,00368	0,372
	Validação	0,00477	0,317	0,00514	0,625
	Teste	0,00325	0,381	0,00347	0,317
6	Treinamento	0,00441	0,435	0,00331	0,354
	Validação	0,00422	0,254	0,00388	0,508
	Teste	0,00480	0,444	0,00420	0,444
10	Treinamento	0,00221	0,190	0,00274	0,245
	Validação	0,00128	0,063	0,00452	0,635
	Teste	0,00387	0,317	0,00277	0,190

Tabela 5.6: Métricas de desempenho obtidos para as redes neurais de alarmes de contaminação da corrente de topo alto e muito alto.

Número de neurônios na camada intermediária	Contaminação da Corrente de Topo	Alarme Alto		Alarme Muito Alto	
		MSE	%E	MSE	E%
3	Treinamento	0,00239	0,136	0,00274	0,340
	Validação	0,00206	0,127	0,00399	0,447
	Teste	0,00286	0,190	0,00150	0,127
6	Treinamento	0,00242	0,081	0,00193	0,177
	Validação	0,00269	0,127	0,00266	0,254
	Teste	0,00275	0,127	0,00212	0,254
10	Treinamento	0,00153	0,095	0,00212	0,149
	Validação	0,00173	0,127	0,00182	0,063
	Teste	0,00272	0,381	0,00198	0,127

Percebe-se que o desempenho de todas as redes neurais melhora muito pouco com o aumento do número de neurônios. Com três neurônios já é obtido um desempenho satisfatório, visto que os erros quadráticos médios e os erros percentuais já apresentam um valor muito baixo. Sendo assim, escolhemos esta configuração, pois assim temos uma maior tendência de extrapolação da rede.

Outra forma de analisar o desempenho das redes é utilizando as matrizes de confusão geradas pelo Matlab. As colunas representam os resultados previstos e as linhas representam o resultado real. Para realizar esta análise, foram selecionadas as redes com três neurônios intermediários.

Novamente percebe-se o bom desempenho das RNAs configuradas. O quadrado em azul no canto inferior direito das matrizes mostra os acertos (em verde) e erros (em vermelho) percentuais totais da rede. Os valores de acerto ficaram, para todos os casos, entre 95 e 100%.

As matrizes de confusão geradas estão na Figura 5.1, Figura 5.2 e Figura 5.3.

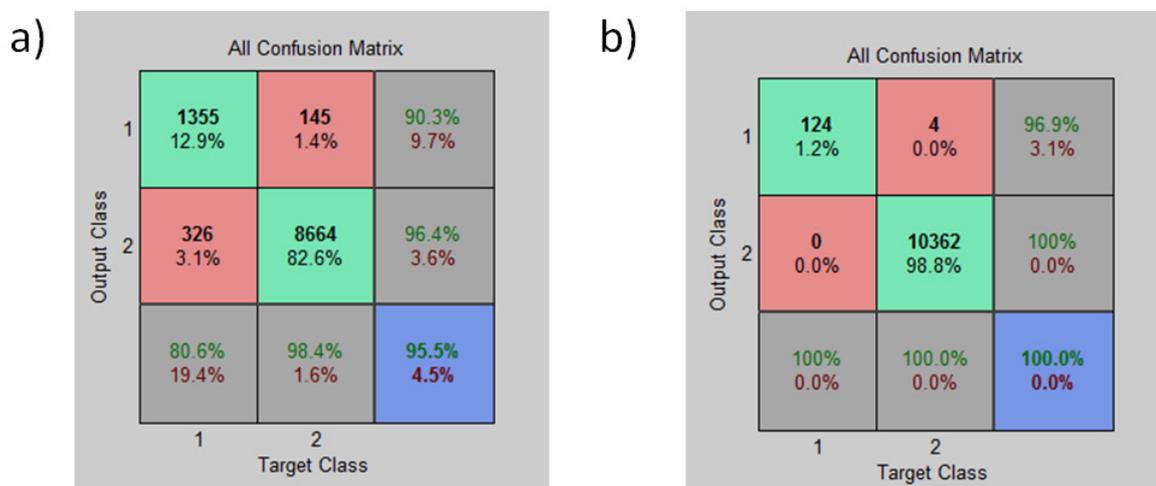


Figura 5.1: Matrizes de confusão para as redes neurais de alarmes de fator de inundação alto (a) e muito alto (b).

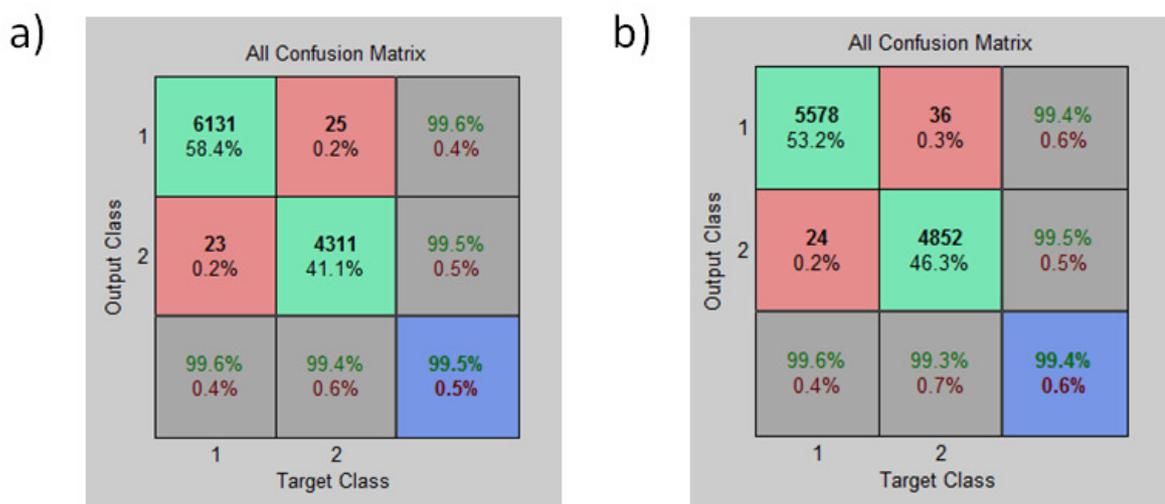


Figura 5.2: Matrizes de confusão para as redes neurais de alarmes de contaminação da corrente de fundo alto (a) e muito alto (b).

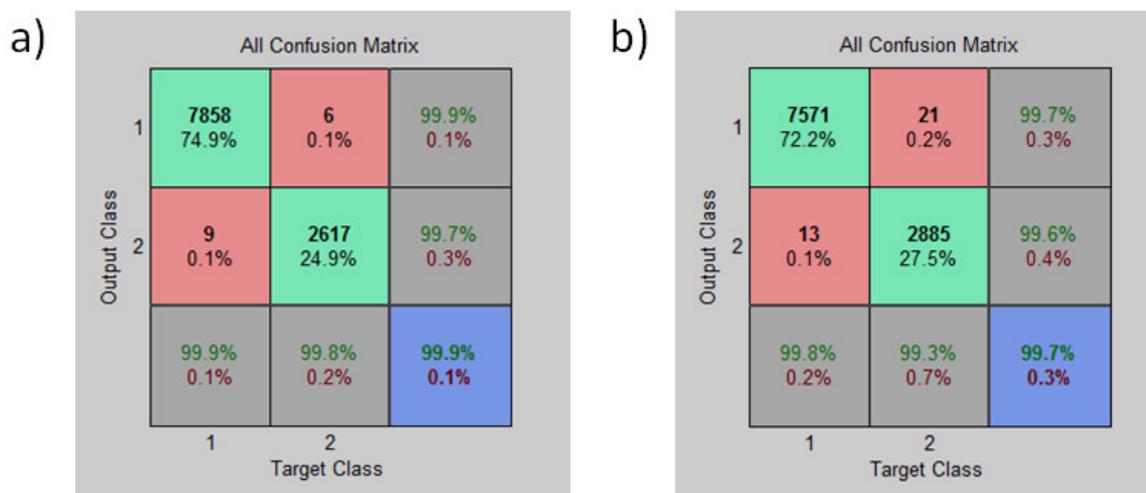


Figura 5.3: Matrizes de confusão para as redes neurais de alarmes de contaminação da corrente de topo alto (a) e muito alto (b).

Na segunda parte do algoritmo, deseja-se obter o tempo desde a aplicação do distúrbio até a transposição do alarme. Para tanto, as RNAs foram configuradas utilizando o *toolbox* do Matlab chamado de *Neural Network Fitting Tool*. Esse *toolbox* possui uma interface gráfica que auxilia na seleção dos dados, criação e treinamento das redes e a avaliação do desempenho das mesmas. A avaliação do desempenho se dá através de duas formas: erro quadrático médio (MSE) e análise de regressão (R) que mede a correlação entre as saídas da rede e os resultados desejados, sendo que valores mais próximos de um significam uma boa aproximação.

O *toolbox* utiliza uma rede do tipo *feedforward*, com neurônios intermediários do tipo tangente sigmoideal e neurônios de saída do tipo lineares que possuem uma boa

capacidade de ajustar dados multidimensionais desde que possua uma quantidade de neurônios suficiente na sua camada intermediária. O algoritmo de treinamento utilizado é o de *backpropagation*.

As métricas de desempenho obtidas para as redes neurais configuradas para a identificação do tempo de alarmes de fator de atolamento alto e muito alto, contaminação da corrente de fundo alto e muito alto e contaminação da corrente de topo alto e muito alto estão dispostos na Tabela 5.7, Tabela 5.8 e Tabela 5.9, respectivamente.

Tabela 5.7: Métricas de desempenho obtidas para as redes neurais para o tempo de atuação de alarmes do fator de inundação alto e muito alto.

Número de neurônios na camada intermediária	Fator de Inundação	Alarme Alto		Alarme Muito Alto	
		MSE	R	MSE	R
3	Treinamento	$1,41 \cdot 10^{-16}$	0,999	$1,58 \cdot 10^{-5}$	0,999
	Validação	$6,83 \cdot 10^{-17}$	0,999	$1,97 \cdot 10^{-4}$	0,994
	Teste	$2,23 \cdot 10^{-16}$	0,999	$1,64 \cdot 10^{-5}$	0,999
6	Treinamento	$1,83 \cdot 10^{-17}$	0,999	$1,49 \cdot 10^{-9}$	0,999
	Validação	$3,98 \cdot 10^{-17}$	0,999	$1,24 \cdot 10^{-5}$	0,999
	Teste	$3,43 \cdot 10^{-17}$	0,999	$4,09 \cdot 10^{-4}$	0,987
10	Treinamento	$1,99 \cdot 10^{-17}$	0,999	$2,76 \cdot 10^{-7}$	0,999
	Validação	$3,80 \cdot 10^{-17}$	0,999	$8,21 \cdot 10^{-6}$	0,995
	Teste	$2,85 \cdot 10^{-17}$	0,999	$7,19 \cdot 10^{-4}$	0,923

Tabela 5.8: Métricas de desempenho obtidas para as redes neurais para o tempo de atuação de alarmes de contaminação da corrente de fundo alto e muito alto.

Número de neurônios na camada intermediária	Contaminação da Corrente de Fundo	Alarme Baixo		Alarme Muito Baixo	
		MSE	R	MSE	R
3	Treinamento	$9,10 \cdot 10^{-14}$	0,999	$1,77 \cdot 10^{-16}$	0,999
	Validação	$1,77 \cdot 10^{-14}$	0,999	$1,93 \cdot 10^{-16}$	0,999
	Teste	$1,85 \cdot 10^{-14}$	0,999	$7,43 \cdot 10^{-17}$	0,999
6	Treinamento	$1,95 \cdot 10^{-16}$	0,999	$3,41 \cdot 10^{-18}$	0,999
	Validação	$6,54 \cdot 10^{-16}$	0,999	$3,83 \cdot 10^{-18}$	0,999
	Teste	$6,27 \cdot 10^{-16}$	0,999	$3,93 \cdot 10^{-18}$	0,999
10	Treinamento	$2,75 \cdot 10^{-17}$	0,999	$2,79 \cdot 10^{-18}$	0,999
	Validação	$1,35 \cdot 10^{-16}$	0,999	$4,12 \cdot 10^{-18}$	0,999
	Teste	$8,76 \cdot 10^{-17}$	0,999	$3,32 \cdot 10^{-18}$	0,999

Tabela 5.9: Métricas de desempenho obtidas para as redes neurais para o tempo de atuação de alarmes de contaminação do topo alto e muito alto.

Número de neurônios na camada intermediária	Contaminação da Corrente de Topo	Alarme Alto		Alarme Muito Alto	
		MSE	R	MSE	R
3	Treinamento	$2,27 \cdot 10^{-4}$	0,991	$3,17 \cdot 10^{-3}$	0,888
	Validação	$4,32 \cdot 10^{-5}$	0,998	$2,19 \cdot 10^{-3}$	0,983
	Teste	$3,54 \cdot 10^{-3}$	0,916	$2,11 \cdot 10^{-3}$	0,965
6	Treinamento	$1,61 \cdot 10^{-5}$	0,999	$1,47 \cdot 10^{-4}$	0,996
	Validação	$1,03 \cdot 10^{-6}$	0,999	$1,41 \cdot 10^{-4}$	0,993
	Teste	$9,58 \cdot 10^{-4}$	0,997	$3,04 \cdot 10^{-4}$	0,984
10	Treinamento	$2,75 \cdot 10^{-6}$	0,999	$8,62 \cdot 10^{-7}$	0,999
	Validação	$1,35 \cdot 10^{-6}$	0,999	$9,15 \cdot 10^{-5}$	0,997
	Teste	$2,68 \cdot 10^{-4}$	0,992	$8,20 \cdot 10^{-4}$	0,980

Percebe-se que o desempenho para todas as redes neurais melhora com o aumento do número de neurônios na camada intermediária. Porém, para as redes neurais com três neurônios já são obtidos erros quadráticos médios muito baixos e coeficientes de regressão com valores bem próximos da unidade. Portanto, visto que sempre buscamos o menor número de neurônios que gere erros aceitáveis, as melhores redes foram as configuradas com três neurônios na camada intermediária. Essas redes conseguiram aproximar as diversas saídas de forma satisfatória, sendo capazes determinar de forma correta o tempo de atuação dos alarmes.

6 Conclusões e Trabalhos Futuros

A operação estável de processos químicos complexos é um dos mais importantes assuntos pesquisados e desenvolvidos pela engenharia química atualmente. Os sistemas de alarmes das unidades são peças chave para não somente manter o processo o mais estável e perto da máxima capacidade possível, mas também para prevenir que distúrbios levem a perdas de qualidade ou produtividade.

Este trabalho mostrou que é possível desenvolver um sistema de alarmes preditivo capaz de antecipar a atuação de um alarme e assim auxiliar o operador a tomar as medidas necessárias para a prevenção da atuação do alarme e de possíveis perdas de produção ou diminuição da segurança do processo. O sistema proposto também cumpriu seus objetivos em determinar o tempo de atuação do alarme, desde a ocorrência do distúrbio.

A aplicação das redes neurais para a previsão de alarmes se mostrou muito satisfatória dado os bons desempenhos apresentados pelas métricas estabelecidas. Primeiramente, as redes configuradas foram capazes de aprender e se adaptar baseadas nos exemplos e obtiveram a capacidade de capturar as relações entre as entradas e saídas podendo assim prever a atuação dos alarmes. A premissa de que as RNAs não necessitam conhecer a origem dos dados de entrada ou saída foi comprovada. Essa capacidade é muito útil visto que, no caso dos alarmes, é mais fácil termos os dados dos resultados das simulações dos diversos estados que levam a atuação dos alarmes, do que as equações e teorias sobre a atuação dos mesmos.

Além disso, as RNAs foram capazes de generalizar o conhecimento. Ou seja, após a fase de treinamento, elas puderam inferir corretamente sobre os dados de entradas que não foram utilizadas na fase de treinamento. Isso pode ser comprovado devido aos baixos erros obtidos nas fases de teste da rede. A fase de teste é a fase que simula a operação real da rede neural, tal como ela seria utilizada em uma situação real de processo.

Por fim as redes configuradas foram capazes de aproximar funções não lineares sem um conhecimento prévio da relação entre as entradas e saídas. Isso pode ser confirmado na previsão do tempo de atuação dos alarmes, na segunda parte do algoritmo. Todas as aproximações tiveram um erro quadrático médio muito baixo e um coeficiente de regressão bem próximo da unidade, mostrando que as funções não lineares obtidas pelas redes se ajustaram quase que perfeitamente aos dados de saída.

A metodologia proposta se mostrou capaz de servir de base para um sistema de predição de alarmes em uma planta de processo real. A configuração das redes neurais só necessitam ser realizadas uma única vez. Depois de configuradas da forma correta, onde se garante um bom desempenho, as redes neurais podem ser implementadas para receber dados diretamente da planta e prever a transgressão de limites de alarmes.

Um grande leque de possibilidades se abre com o bom desempenho, demonstrado neste trabalho, das RNAs como base para um sistema preditivo de alarmes. Um trabalho mais detalhado englobando mais variáveis, mais distúrbios e mais alarmes deve ser feito para se ter um completo mapeamento de todo o funcionamento da unidade despropanizadora. A aplicação da metodologia na planta real é de grande importância para comprovar o bom desempenho da metodologia. Além disso, fica como sugestão a integração da metodologia com um filtro de Kalman para minimizar ruídos e o efeito dos

erros de medição. Para futuros estudos também se pode citar a expansão da metodologia e do algoritmo proposto para mais sistemas e para diferentes operações unitárias. Sistemas de reatores que possuem pontos de operação bastante críticos e operação delicada podem servir de base para aplicar testar a resposta desta metodologia.

7 Referências

ANSI/ISA ISA18.00.02-2009 "Management of Alarm Systems for the Process Industries".

BASHEER, I.A.; HAJMEER, M. Artificial neural networks: fundamentals, computing, design, and application. **Journal of Microbiological Methods**, v.43, n.1,p.3-31, 1995.

BEEBE, D.; FERRER, S.; LOGEROT, D. The connection of peak alarm rates to plant incidents and what you can do to minimize. **Process Safety Progress**, v. 32, n. 1, p. 72-77, // 2013. Disponível em: <<http://www.scopus.com/inward/record.url?eid=2-s2.0-84874243757&partnerID=40&md5=4d9668b2581de09630c6fc265960fa3a>>.

DUNN, D. G.; SANDS, N. P. ISA-SP18 - Alarm systems management and design guide. 2005. p.313-320.

FAUSETT, L. Fundamentals of Neural Networks: architectures, algorithms, and applications. Englewood Cliffs, N.J.: Prentice-Hall International, 1994.

GOTO, K.; TORIYAMA, Y.; ITOH, O. Intelligent alarm method by fuzzy measure and its application to plant abnormality prediction. 1995. p.395-400.

ZHANG, B.G.; PATUWO, B.E. Forecasting with artificial neural networks: the state of the art. **International Journal of Forecasting**.v. 14,. p.35-62, 1998.

HOSKINS, J. C.; HIMMELBLAU, D. M. Artificial neural network models of knowledge representation in chemical engineering. **Computers and Chemical Engineering**, v. 12, n. 9-10, p. 881-890, // 1988. Disponível em: <<http://www.scopus.com/inward/record.url?eid=2-s2.0-0040287998&partnerID=40&md5=c72d3f8870737de58cb0a3370985a922>>.

ISERMANN, R. Process fault detection based on modeling and estimation methods-A survey. **Automatica**, v. 20, n. 4, p. 387-404, // 1984. Disponível em: <<http://www.scopus.com/inward/record.url?eid=2-s2.0-0021468997&partnerID=40&md5=bedd256e3ab639850d53df2c6dd0b8fb>>.

JURICEK, B. C.; SEBORG, D. E.; LARIMORE, W. E. Predictive monitoring for abnormal situation management. **Journal of Process Control**, v. 11, n. 2, p. 111-128, // 2001. Disponível em: <<http://www.scopus.com/inward/record.url?eid=2-s2.0-0035310481&partnerID=40&md5=c61218142a73a73e5dd9292de96e2d84>>.

KIM, I. S.; MODARRES, M.; HUNT, R. N. M. A model-based approach to on-line process disturbance management: The models. **Reliability Engineering and System Safety**, v. 28, n. 3, p. 265-305, // 1990. Disponível em: <<http://www.scopus.com/inward/record.url?eid=2-s2.0-0025249593&partnerID=40&md5=d0381585e64a44900d162c6f328e377d>>.

STAUFFER, T. Implement an effective alarm management program. **Chemical Engineering Progress**, v. 108, n. 7, p. 19-27, // 2012. Disponível em: <<http://www.scopus.com/inward/record.url?eid=2-s2.0-84863451240&partnerID=40&md5=c8e742141a04d3a5328bc36a072dab14>>.

VARGA, T.; SZEIFERT, F.; ABONYI, J. Detection of safe operating regions: A novel dynamic process simulator based predictive alarm management approach. **Industrial and Engineering Chemistry Research**, v. 49, n. 2, p. 658-668, // 2010. Disponível em: <<http://www.scopus.com/inward/record.url?eid=2-s2.0-75249088436&partnerID=40&md5=a7673122a7c8fbb3eafd6323591854a2>>.

VENKATASUBRAMANIAN, V. et al. A review of process fault detection and diagnosis part I: Quantitative model-based methods. **Computers and Chemical Engineering**, v. 27, n. 3, p. 293-311, // 2003. Disponível em: <<http://www.scopus.com/inward/record.url?eid=2-s2.0-0037443770&partnerID=40&md5=d888930fe6b854776d04807607373aa0>>.