

# *Monografia de Graduação*

## **Desenvolvimento de um Sistema de Monitoração da Deposição de FeS em uma Unidade de Refino de Petróleo**

**Victor Leonardo Cavalcante Melo da Silva**

**Natal, Julho de 2010**

**Universidade Federal do Rio Grande do Norte**  
**Departamento de Engenharia de Computação e Automação**

**Desenvolvimento de um Sistema de Monitoração  
da Deposição de FeS em uma Unidade de Refino  
de Petróleo**

**Victor Leonardo Cavalcante Melo da Silva**

**Orientador: Prof. Dr. Jorge Dantas de Melo**

**Trabalho de Conclusão de Curso,  
submetido ao Departamento de  
Engenharia de Computação e  
Automação do Centro de  
Tecnologia da Universidade Federal  
do Rio Grande do Norte, como  
parte dos requisitos necessários  
para a obtenção do grau de  
Graduado.**

**Natal, Junho de 2010**

## Agradecimentos

Aos meus pais, irmãos e família, por tudo.

Aos professores do DCA, em especial ao orientador Jorge e ao professor Adrião, pelos ensinamentos.

Ao colega e amigo Thiago Medeiros, pelo apoio técnico e companheirismo.

Aos colegas de projeto Hanniel, Alexandre e Kennedy, pelo apoio durante as atividades.

A todos os colegas e amigos da graduação, em especial a João Teixeira, Samuel Paulino, Daniel Guerra e Leidson Germano, pelo apoio durante o curso.

A minha namorada Andréa Karla, por estar ao meu lado.

Aos amigos Judismar Arpini e Erick Cortez, pelo companheirismo.

Ao amigo Ivan Barreto, por ter me acompanhado em vários momentos.

Ao Programa de Recursos Humanos da ANP / PRH-14, pelo apoio financeiro.

## Resumo

Um sério problema que afeta unidades de refino de petróleo é a deposição e incrustação de sólidos nos equipamentos. O petróleo produzido no Rio Grande do Norte em particular contém grande teor de sais, restos orgânicos, limalha de ferro e sujeiras que se depositam nos equipamentos da Unidade de Destilação Atmosférica U-270, da Refinaria Potiguar Clara Camarão. A deposição ocorre principalmente nos pratos das torres de destilação e nos trocadores de calor que pré-aquecem o óleo bruto, causando diversos problemas. O presente trabalho desenvolveu um sistema baseado em redes neurais artificiais do tipo perceptron de múltiplas camadas capaz de monitorar o nível da deposição no processo. As redes organizam-se de forma autoassociativa para realizar uma compressão dos dados de entrada, extraindo os seus principais componentes, formando uma curva indicadora da deposição.

**Palavras-chave:** redes neurais artificiais, compressão de dados, análise de componentes principais, deposição, refino de petróleo.

## Sumário

Agradecimentos .....	iii
Resumo.....	iv
Lista de Figuras .....	vi
1. Introdução .....	1
1.1 Motivação.....	1
1.2 Objetivos .....	1
1.3 Organização do Trabalho .....	2
2. Deposição e Incrustação na Indústria do Petróleo .....	3
3. Unidade de Destilação Atmosférica de QAV da Refinaria Potiguar Clara Camarão .....	7
3.1 Linhas da Unidade de Destilação Atmosférica .....	7
3.1.1 Linha de Óleo Cru .....	7
3.1.2 Linha de Resíduo Atmosférico (RAT) .....	8
3.1.3 Linhas de Diesel.....	8
3.1.4 Linhas de Querosene .....	9
3.1.5 Linha de Topo .....	9
3.1.6 Linha de Água Industrial.....	10
3.2 O Problema da Deposição na Refinaria.....	12
4. Redes Neurais Artificiais.....	14
4.1 Introdução .....	14
4.2 Propriedades das Redes Neurais Artificiais.....	15
4.3 Modelo de um Neurônio Artificial .....	16
4.4 Perceptron de Múltiplas Camadas .....	18
4.5 Compressão de Dados Utilizando Perceptron de Múltiplas Camadas.....	21
5. Metodologia .....	25
5.1 Proposta do Trabalho.....	25
5.2 Coleta e Análise de Dados .....	25
5.3 Desenvolvimento do Sistema Indicador da Deposição .....	30
6. Resultados Obtidos .....	33
7. Conclusão .....	45
Referências Bibliográficas .....	46

## Lista de Figuras

Figura 1 - Esquema de um trocador de calor "casco e tubos" típico .....	3
Figura 2 – Trocadores de calor (permutadores) P-27001, P-27002, P-27003 e P-27004.....	10
Figura 3 - Dessalgadores DL-27001A e DL-27001B .....	11
Figura 4 - Forno F-27001 .....	11
Figura 5 - Torres atmosféricas T-27001, T-27002 e T-27003 .....	12
Figura 6 - Modelo de um Neurônio Artificial .....	17
Figura 7 - Função limiar .....	17
Figura 8 - Função sigmóide com $\alpha = 1$ .....	18
Figura 9 - Função tangente sigmoide hiperbólica .....	18
Figura 10 - Perceptron de Múltiplas Camadas com duas camadas ocultas e uma camada de saída .....	19
Figura 11 - Rede autoassociativa com uma única camada oculta .....	22
Figura 12 - Rede reconstrutora (descompressora) .....	23
Figura 13 - Autoassociador com três camadas ocultas .....	23
Figura 14 - Curva original do TI-03 .....	27
Figura 15 - Curva do TI-03 após aplicação do filtro da média móvel .....	27
Figura 16 – Curva do TI-03 após a aplicação do filtro da média móvel e dos limites .....	28
Figura 17 - Rede neural para compressão de dados .....	31
Figura 18 - Exemplo de formação do conjunto de entrada para a rede .....	31
Figura 19 - Erro de treinamento para a rede 16:16:1:16:16 .....	34
Figura 20 - Curva reconstruída do TI-03 pela rede 16:16:1:16:16 .....	34
Figura 21 - Curva reconstruída do TI-04 pela rede 16:16:1:16:16 .....	35
Figura 22 - Curva reconstruída do TI-14 pela rede 16:16:1:16:16 .....	35
Figura 23 - Curva reconstruída do TI-15 pela rede pela rede 16:16:1:16:16 .....	36
Figura 24 - Curva de saída da camada de representação da rede 16:16:1:16:16. A linha vermelha indica o momento da parada para manutenção. ....	36
Figura 25 - Erro de treinamento para a rede 64:32:1:32:64 .....	38
Figura 26 - Curva reconstruída do TI-03 pela rede 64:32:1:32:64 .....	38
Figura 27 - Curva reconstruída do TI-04 pela rede 64:32:1:32:64 .....	39
Figura 28 - Curva reconstruída do TI-14 pela rede 64:32:1:32:64 .....	39
Figura 29 - Curva reconstruída do TI-15 pela rede 64:32:1:32:64 .....	40
Figura 30 - Curva de saída da camada de representação da rede 64:32:1:32:64. A linha vermelha indica o momento da parada para manutenção. ....	40
Figura 31 - Erro de treinamento para a segunda rede 16:16:1:16:16 .....	41
Figura 32 - Curva reconstruída do TI-03 pela segunda rede 16:16:1:16:16.....	41
Figura 33 - Curva reconstruída do TI-04 pela segunda rede 16:16:1:16:16.....	42
Figura 34 - Curva reconstruída do TI-14 pela segunda rede 16:16:1:16:16.....	42
Figura 35 - Curva reconstruída do TI-15 pela segunda rede 16:16:1:16:16.....	43
Figura 36 - Curva de saída da camada de representação da segunda rede 16:16:1:16:16. A linha vermelha indica o momento da parada para manutenção. ....	43

## 1. Introdução

### 1.1 Motivação

O Rio Grande do Norte é um dos maiores produtores de petróleo em terra do Brasil e boa parte desse petróleo é refinada localmente, na Refinaria Potiguar Clara Camarão (RPCC), localizada no município de Guamaré. Apesar do petróleo produzido no estado ser de boa qualidade, com elevado grau API, ele possui alto teor de ácido sulfídrico ( $H_2S$ ), prejudicial para os equipamentos da refinaria, pois causa corrosão e se deposita sob a forma de sulfeto de ferro ( $FeS$ ). A deposição de sais, restos orgânicos e sujeiras em geral diminui a eficiência do processo de refino gradativamente, até um ponto em que é necessário parar o sistema para realizar a limpeza dos equipamentos. Esse problema ocorre principalmente nas bandejas e permutadores da coluna de destilação para produção de querosene de aviação (QAV), que pode ficar até uma semana parada para limpeza, causando grande perda de produção e alto custo de manutenção.

### 1.2 Objetivos

O objetivo deste trabalho é desenvolver um sistema capaz de extrair informação de algumas das variáveis do processo de refino de QAV para monitorar a degradação causada pela deposição de material na coluna. Dessa forma, o sistema funciona como um indicador da deposição, podendo no futuro ser utilizado em conjunto com um sistema de controle adaptativo para realizar compensações no processo, de forma a aumentar a sua eficiência e diminuir o intervalo entre paradas consecutivas para limpeza, diminuindo os custos operacionais. O sistema indicador será basicamente uma rede neural artificial do tipo perceptron de múltiplas camadas, treinada de forma auto-supervisionada para realizar um PCA (Análise dos Principais Componentes) não linear, ou seja, uma compressão de dados sobre as variáveis de processo, obtendo como resultado uma curva indicadora da deposição. Outros trabalhos em que redes neurais artificiais foram aplicadas à indústria do petróleo podem ser vistos em (REBOUÇAS, 2009) e (ZANATA, 2005).

### 1.3 Organização do Trabalho

O restante do trabalho está organizado em capítulos. No segundo capítulo haverá uma descrição mais detalhada do problema da deposição e incrustação, que ocorre em particular nos trocadores de calor da refinaria.

O terceiro capítulo aborda o processo de refino de petróleo para produção de derivados na RPCC e como essa refinaria é afetada pela corrosão e deposição, relatando-se o que é feito atualmente para tratar o problema.

No quarto capítulo haverá uma revisão bibliográfica sobre redes neurais artificiais e, em particular, sobre a aplicação de perceptrons de múltiplas camadas para a compressão de dados.

No quinto capítulo haverá a proposta e a metodologia do trabalho, com a descrição das tarefas realizadas para o desenvolvimento de um sistema indicador da deposição.

No sexto capítulo serão demonstrados os resultados obtidos a partir de algumas das redes neurais treinadas nesse trabalho.

Finalmente, no sétimo capítulo, apresentam-se as conclusões e perspectivas para trabalhos futuros.

## 2. Deposição e Incrustação na Indústria do Petróleo

Os problemas de deposição e incrustação de materiais são frequentes e ocorrem nas mais diversas atividades industriais. Entre as atividades em que a deposição é um fator muito importante, destacam-se as atividades de refino e processamento de petróleo. O tratamento do óleo cru em uma torre de destilação é a primeira etapa do refino e processamento do óleo e, conseqüentemente, estas unidades são as mais afetadas por problemas de deposição. Este processo de destilação consiste na fragmentação e separação do óleo cru em determinados produtos de acordo com a pressão de vapor e o ponto de ebulição de cada produto. Durante o processo de destilação, materiais e sujeiras presentes no óleo podem se depositar nos equipamentos e tubulações e causar problemas de incrustação. Esses problemas são muito custosos, pois aumentam o gasto com combustíveis (maior consumo nos fornos de aquecimento, por exemplo), causam interrupções na operação, perda na produção e gastos com manutenção.

O óleo cru que alimenta uma unidade de destilação atmosférica em geral passa por um processo de pré-aquecimento, passando por trocadores de calor antes de entrar na torre. Um trocador de calor é um equipamento onde ocorre uma troca térmica entre dois fluidos, normalmente sem haver um contato direto entre eles. Há diversos tipos construtivos, dentre os quais um dos mais usados industrialmente é o de feixe tubular, constituído por um conjunto de tubos envolto por um casco. Um dos fluidos circula no interior dos tubos e o outro fluido escoo no lado externo, como mostra a figura 1.

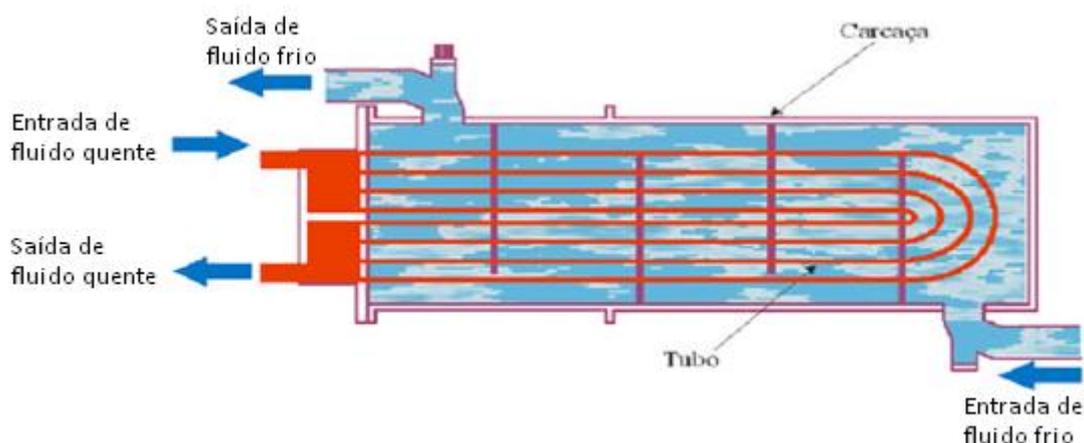


Figura 1 - Esquema de um trocador de calor "casco e tubos" típico

Esses trocadores de calor utilizados em plantas industriais são, em particular, fortemente prejudicados com a incrustação. O material particulado indesejável trazido pelo

óleo cru (fluido frio) se deposita nos tubos internos do trocador. Esse depósito aumenta a resistência à transferência de energia, diminuindo a eficiência de troca térmica, de forma que a temperatura de saída do óleo será menor e ele entrará mais frio na torre, diminuindo a eficiência do processo como um todo. Além disso, o depósito pode obstruir a passagem do fluido, aumentando a sua perda de carga.

Um dos modos adotados na prática para saber o grau de depósito num trocador de calor em operação é acompanhar, ao longo do tempo de uso, as temperaturas e as pressões terminais do trocador. À medida que o depósito aumenta, a eficiência de troca térmica cai (observado através das temperaturas) e a diferença de pressões cresce (SONG, 1998).

O processo de formação da deposição é em geral complexo. Alguns dos principais mecanismos são:

- **Cristalização:** ocorre devido à supersaturação com a conseqüente deposição de sais.
- **Decomposição de produtos orgânicos ou coqueamento:** as superfícies do trocador podem ficar cobertas com alcatrão ou coque produzidos por reações químicas. Essas reações ocorrem próximas à superfície quente e produzem partículas sólidas ou alcatrão muito viscoso que se acumulam nos tubos.
- **Polimerização ou oxidação:** consiste em reações químicas que formam uma camada plástica cuja remoção pode ser complexa.
- **Depósito de lodo, ferrugem ou partículas de poeira:** consiste no depósito de partículas sólidas nas superfícies do trocador. Muitos fluidos, como o petróleo bruto produzido no Rio Grande do Norte, contém diversas partículas sólidas em suspensão. Alguns tipos de partículas podem inclusive assar na superfície do trocador, complicando ainda mais sua limpeza.
- **Deposição biológica:** algas, fungos e bactérias podem consumir nutrientes em suspensão e formar limos que se prendem à superfície do trocador. Os limos podem ainda servir como ponto de partida para bactérias anaeróbicas causadoras de corrosão.
- **Corrosão:** esse processo consiste na oxidação de metais, causada por oxigênio ou ácidos dissolvidos no fluido. A corrosão causa a formação de camadas de ferrugem nas tubulações.

Esses mecanismos podem ocorrer independente ou paralelamente. A taxa de depósito é afetada pelas condições de processo do trocador tais como a natureza dos fluidos, a velocidade de escoamento, as temperaturas dos fluidos, a temperatura na parede, o material

de construção do equipamento, o grau de acabamento da superfície como a rugosidade ou tipo de revestimento interno. A deposição é mais expressiva nos tubos do fluido frio, pois as impurezas se dissolvem com mais dificuldade a baixas temperaturas. Isto ocorre porque a solubilidade da maior parte das substâncias cresce proporcionalmente à temperatura.

Para facilitar a quantificação do efeito da deposição, costuma-se usar um parâmetro definido como fator de incrustação ou fator de sujeira (*fouling factor*). Dimensionalmente é o inverso do coeficiente de transporte de energia por convecção. Logo, quanto maior o fator de incrustação, maior o depósito, maior a resistência à troca térmica. O fator de incrustação deve ser considerado a priori num projeto de trocador de calor, pois a área de troca térmica calculada deve ser suficiente para as necessidades do processo quando o trocador está novo (limpo) e quando está em operação há algum tempo (já com sujeira). Como o valor desse fator é difícil de ser previsto, essa deficiência constituirá uma das causas principais da imprecisão no projeto de um trocador de calor (SONG, 1998).

Em um processo de produção de derivados do petróleo, é comum a prática de medidas para evitar e combater possíveis problemas de deposição. A dessalgação é uma das mais importantes etapas do processo de destilação para o controle da corrosão e da deposição. A dessalgação consiste na remoção de sais, água e suspensões de partículas sólidas, permitindo assim maior flexibilidade operacional em relação aos tipos de petróleos processados e, principalmente, evitando que problemas de corrosão se agravem com a geração de ácido clorídrico. Em um processo de dessalgação, o petróleo preaquecido recebe uma corrente de água de processo para misturar com a água residual, sais e sólidos presentes na carga. Uma válvula misturadora provoca o íntimo contato entre a água injetada, os sais e os sedimentos. A seguir, a mistura de petróleo, água e impurezas, já na dessalgadora, passa por um campo elétrico de alta voltagem, mantido entre pares de eletrodos metálicos existentes no equipamento de dessalgação. As forças de campo assim criadas provocam a formação de muitas gotas grandes que, pelo aumento de sua densidade, se precipitam no fundo da dessalgadora, carregando sais e sedimentos (GONÇALVES, 2007).

O grande limitante ao processo de dessalgação é o fato de petróleos oriundos dos tanques estarem muito carregados com resíduos sólidos devido ao baixo tempo de residência adotado na operação. Esse fator prejudica muito o processo de dessalgação, sendo que parte da solução aquosa, que deveria ser efluente da dessalgadora, pode continuar no processo, gerando problemas de corrosão nas etapas posteriores. Os ácidos formados a partir da hidrólise dos sais que não foram retidos na dessalgadora vão para o topo da torre, provocando

reações químicas que corroem o ferro. Outro problema também presente no sistema é a formação de incrustações devido à presença de sais que se depositam em áreas próximas ao permutador de calor, na linha de topo e no condensador. Algumas refinarias utilizam duas dessalgadoras em série exatamente para aumentar a eficiência na remoção dos sais. Entretanto, mesmo com eficiente dessalgação, normalmente resíduos de sais ainda são encontrados no topo, em níveis que podem causar deposição de incrustações e problemas de corrosão (GONÇALVES, 2007).

Quando a deposição e incrustação atingem um nível crítico, é necessário parar a coluna para a realização de atividades de manutenção. Trocadores de calor podem ser limpos com jatos de água pressurizados, ácidos de limpeza, jatos de areia, entre outros. Para evitar as perdas devido às paradas para manutenção, é importante estudar métodos para inibir ou atenuar o efeito da deposição e da incrustação, e o que pode ser alterado na malha de controle para compensar esses efeitos, garantindo uma maior produtividade e diminuindo a frequência das paradas.

### 3. Unidade de Destilação Atmosférica de QAV da Refinaria Potiguar Clara Camarão

As informações descritas nessa seção foram obtidas a partir de uma visita técnica à refinaria, análise dos seus fluxogramas de processo e uma conversa com os seus operadores e engenheiros.

A Unidade de Destilação Atmosférica (U-270) produz combustíveis cuja composição reflete a volatilidade dos componentes presentes no petróleo que a alimenta. Os produtos mais pesados, com maior ponto de ebulição, são retirados na base das torres, enquanto que os produtos mais leves, com menor ponto de ebulição, são retirados em pontos mais altos. A Unidade produz, em ordem decrescente de peso, o resíduo atmosférico (RAT), o diesel, o querosene de aviação (QAV) e o nafta. A Unidade possui, no total, oito linhas de fluxo principais considerando os dois casos operacionais (caso A e caso B), sendo duas linhas de óleo diesel das bombas B-27004A/B e B-27006/B, uma linha de resíduo atmosférico (RAT) da bomba B-27007A/B, uma linha de óleo cru, duas linhas de querosene das bombas B-27005A/B e B-27003A/B, uma linha de nafta da bomba B-27002A/B e uma linha de água industrial.

#### 3.1 Linhas da Unidade de Destilação Atmosférica

A seguir temos uma descrição das linhas de fluxo da Unidade de Destilação Atmosférica U-270.

##### 3.1.1 Linha de Óleo Cru

O óleo cru recebe inicialmente uma substância inibidora de incrustações e uma substância desemulsificante, que auxilia a separar a água do óleo. O óleo é então misturado a água industrial e aquecido por meio de quatro trocadores de calor ou permutadores, os P-27001, P-27002, P-27003 e P-27004, que extraem energia das linhas de alimentação de querosene, diesel e RAT. Depois de aquecida, a mistura de óleo cru precisa ser dessalgada para posterior destilação, sendo utilizados dois vasos dessalgadores horizontais em série, o DL-27001A e o DL-27001B. A mistura alimenta inicialmente o DL-27001A, que por sua vez possui duas linhas de saída. Uma linha de saída do DL-27001A conduz óleo dessalgado que recebe mais substância desemulsificante e é misturado a mais água industrial, alimentando posteriormente o DL-27001B. A outra linha conduz a salmoura extraída do vaso, que é aquecida por meio de um trocador de calor com água industrial e misturada a água ácida e

soda gasta, sendo finalmente levada a uma bacia de retenção. O vaso DL-27001B também possui duas linhas de saída. A primeira delas funciona como uma vazão de refluxo, conduzindo a salmoura extraída desse vaso até o vaso DL-27001A, aumentando a eficiência do processo. A segunda linha de saída conduz o óleo dessalgado até o forno de aquecimento F-27001. Antes de chegar ao forno, o óleo recebe uma solução de neutralização e é aquecido por meio de quatro trocadores de calor, os P-27005, P-27007, P-27008 e P-27006, sendo os três primeiros associados a linhas de RAT e o último associado a uma linha de óleo diesel. As linhas de saída do forno F-27001 são combinadas e alimentam a base da torre atmosférica T-27001 no prato 32.

### 3.1.2 Linha de Resíduo Atmosférico (RAT)

A torre T-27001 possui uma interface de saída de fundo responsável por extrair da coluna os compostos mais pesados existentes na mistura de alimentação. Neste caso, o RAT é o produto extraído no fundo da coluna. A linha de RAT passa inicialmente pelo refervedor de óleo diesel (P-27010) da torre. Posteriormente, aquece o óleo cru através dos trocadores de calor P-27004, P-27005, P-27007 e P-27008, recebendo em seguida a linha de nafta e sendo então resfriada a ar pelo trocador P-27014. O RAT resultante dessa linha é misturado a uma corrente de salmoura e óleo diesel antes de ser finalmente estocado.

### 3.1.3 Linhas de Diesel

O segundo produto retirado da torre T-27001, em ordem de altura, é o diesel, dividido em duas linhas. A primeira linha é impulsionada pelas bombas B-27004A/B, aquece o óleo cru através do trocador de calor P-27006 e então realimenta a torre T-27001, no prato 22, para maior refino. A outra linha atua como carga de alimentação para a torre T-27003, que realiza mais um processo de destilação sobre o diesel.

Parte da saída de fundo da T-27003 é impulsionada pelas bombas B-27006A/B, aquece o óleo cru através do trocador P-27003A/B e é resfriada a ar pelo trocador P-27013, ajustando sua temperatura para estocagem. O diesel resultante é então misturado a querosene fora de especificação e é armazenado. A outra parte da saída de fundo é aquecida a partir de troca térmica com o RAT no refervedor P-27010 e retorna para a torre T-27001, como vazão de refluxo de fundo, auxiliando na manutenção do perfil térmico da torre. A saída de topo da T-27003 extrai os componentes mais leves do diesel e funciona como vazão de refluxo para a T-27001.

### 3.1.4 Linhas de Querosene

A terceira interface de saída da torre T-27001 é a do querosene, que percorre dois caminhos distintos. No primeiro, o fluxo é impulsionado pela bomba B-27003A/B e passa pelo trocador de calor P-27002, resfriando-se e aquecendo o óleo cru. O querosene dessa linha realimenta a torre, no prato 9, funcionando como refluxo.

No outro caminho, o querosene atua como carga de alimentação para uma segunda torre de destilação, a T-27002, que possui duas interfaces de saída. Na primeira delas, parte do produto de fundo resultante da destilação é impulsionado pela a bomba B-27005A/B e passa pelo trocador P-27001, aquecendo também o óleo cru. Em seguida, é resfriada a ar pelo trocador P-27012, ajustando sua temperatura para posterior tratamento na unidade U-280. A outra parte é aquecida pelo refeedor P-27009, recebendo energia a partir de um fluxo de óleo térmico proveniente da unidade U-260, e retorna como refluxo de fundo para a T-27001. A saída de topo da T-27002 extrai os componentes mais leves da mistura de querosene e funciona como uma vazão de refluxo para a torre principal, no prato 22.

### 3.1.5 Linha de Topo

A quarta e última interface de saída da torre T-27001 extrai os componentes mais leves do petróleo, que compreendem uma mistura de nafta, gás residual e água ácida. Essa mistura inicialmente recebe uma substância inibidora de corrosão e é em seguida neutralizada com uso de amônia. Posteriormente ela é resfriada no condensador de topo da torre atmosférica (P-27011) e armazenada no vaso de condensado V-27001, que gera três saídas distintas.

A primeira saída do vaso é composta de nafta, que percorre dois caminhos. No primeiro, parte do nafta é enviado para o P-27014 e parte retorna para a coluna de destilação, auxiliando na manutenção do seu perfil de temperatura. No outro caminho o nafta é impulsionado pela bomba B-27002 e adicionado ao fluxo de RAT. A segunda saída do vaso é composta de água ácida que é impulsionada pela bomba B-27012A/B e conduzida à bacia de retenção. A terceira saída é composta pelos gases que correspondem aos componentes mais leves resultantes do processo de destilação. Parte desse gás é queimada no *flare* (chama) da refinaria, por motivos de segurança, controlando a pressão no vaso. Outra parte do gás é armazenada no vaso depurador V-27007 e conduzida ao compressor de gás C-27001A/B,

possibilitando tanto o armazenamento no vaso V-401-101 quanto uma vazão de refluxo para o V-27001.

Atualmente, o nafta é adicionado totalmente à linha de resíduo atmosférico. Está previsto que a partir de dezembro de 2010, com a expansão da refinaria, o nafta passe a fazer parte de uma mistura para a produção de gasolina.

### 3.1.6 Linha de Água Industrial

A linha de água industrial é utilizada para se misturar ao óleo cru que alimenta a linha inicial do processo e ao óleo que alimenta a dessalgadora DL-27001B, servindo também para aquecer a salmoura resultante da dessalgadora DL-27001A, nos trocadores de calor P-27015A/B.

As figuras 2, 3, 4 e 5 a seguir mostram os equipamentos as torres da refinaria.



Figura 2 – Trocadores de calor (permutadores) P-27001, P-27002, P-27003 e P-27004



Figura 3 - Dessalgadores DL-27001A e DL-27001B



Figura 4 - Forno F-27001



Figura 5 - Torres atmosféricas T-27001, T-27002 e T-27003

### 3.2 O Problema da Deposição na Refinaria

O petróleo proveniente dos campos produtores do RN e CE chega à RPCC através de oleodutos levando grande quantidade de  $H_2S$ , sais, restos orgânicos, limalha de ferro e sujeiras em geral. Os operadores relataram que, apesar de também haver corrosão na coluna, o principal problema é a deposição e incrustação desse material presente no óleo que alimenta as torres. Essas substâncias, arrastadas naturalmente devido ao processo de produção de petróleo, se depositam nos equipamentos, sobretudo nos trocadores de calor e nos pratos da torre de destilação de QAV. A deposição causa uma série de problemas:

- Menor eficiência da coluna;
- Produto com menor teor de pureza;
- Dificuldade de controle;
- Aumento do consumo energético;
- Desbandejamento da coluna.

Pratos sujos e corroídos prejudicam a troca de calor entre os componentes menos voláteis e mais voláteis, dificultando o controle das variáveis da coluna, alterando a qualidade dos produtos. A obstrução causada pela deposição nos pratos no meio da coluna causam

também um aumento na pressão no fundo da coluna e uma diminuição da pressão no topo, podendo até mesmo ocorrer desbandejamento, um problema muito grave. Os trocadores de calor também são prejudicados, sendo um dos principais indicadores da deposição de sujeira na torre, isso porque ocorre uma diminuição da troca de energia entre as correntes de querosene circulante da coluna e a carga de alimentação de óleo cru, o que tem por consequência uma menor temperatura fornecida à linha de óleo cru. Para contornar o problema, é realizado um *bypass* nos trocadores, a fim de limpá-los. Com esse *bypass*, o óleo cru chega mais frio à coluna, sendo necessário aumentar a energia gasta no forno para aquecê-lo até a temperatura desejada de 375°C, aumentando os custos energéticos. Os filtros das bombas também se sujam com a deposição, causando uma diminuição da vazão. Por esses motivos, conclui-se que as variáveis de temperatura, pressão e vazão são as principais indicadoras da deposição de sujeira no processo.

Atualmente, a deposição na refinaria é combatida com o uso de dessalgadoras e filtros convencionais, para reter parte da sujeira. Além disso, filtros magnéticos estão sendo utilizados em fase de teste para diminuir o arraste do sulfeto de ferro, combatendo a sua deposição. O uso desses filtros comprovou a grande quantidade de ferro presente no petróleo proveniente dos campos do estado. No entanto, a deposição ainda atinge níveis preocupantes, sendo necessário realizar manutenções frequentes nos equipamentos.

## 4. Redes Neurais Artificiais

### 4.1 Introdução

O desenvolvimento das redes neurais artificiais foi motivado pelo reconhecimento de que o cérebro humano processa informações de uma forma inteiramente diferente do computador digital convencional. O cérebro é um computador (sistema de processamento de informação) altamente complexo, não linear e paralelo. Ele tem a capacidade de organizar seus constituintes estruturais, conhecidos por neurônios, de forma a realizar certos processamentos muito mais rapidamente que o mais rápido computador digital hoje existente (HAYKIN, 2000).

Na sua forma mais geral, uma rede neural artificial é uma máquina construída inspirada na maneira como o cérebro realiza uma tarefa ou função em particular. Essa rede é geralmente implementada a partir de componentes eletrônicos ou simulada através da programação em um computador digital. Para alcançarem um bom desempenho, as redes neurais empregam uma interligação maciça de células computacionais simples, denominadas neurônios artificiais. Essa tecnologia é multidisciplinar, com raízes na neurociência, matemática, estatística, física, ciência da computação e engenharia (HAYKIN, 2000).

Uma rede neural artificial pode ser definida como um processador paralelo distribuído, composto de unidades de processamento simples, que tem a propensão natural para armazenar conhecimento experimental. Essas estruturas se assemelham ao cérebro humano em dois aspectos (HAYKIN,2000):

- Possui capacidade de adquirir conhecimento a partir do ambiente, através de um processo de aprendizagem.
- O conhecimento é armazenado nos pesos sinápticos, as forças de conexões entre os neurônios que constituem a rede.

O processo de aprendizagem de uma rede neural consiste no ajuste dos seus pesos sinápticos, utilizando um algoritmo de aprendizagem. A partir do aprendizado, as redes neurais são capazes de estabelecer relações não lineares entre suas entradas e saídas e podem generalizar e se adaptar a novas situações. São utilizadas em diversas áreas do processamento inteligente da informação, como na classificação de padrões, filtragem de sinais, compressão de dados, processamento de imagens e identificação de sistemas.

É preciso reconhecer que ainda existe um longo caminho até o desenvolvimento de uma rede neural artificial capaz de imitar o cérebro humano. Os modelos atuais são apenas inspirados em um conhecimento primitivo das funções do sistema nervoso e são extremamente simplificados quando comparados ao cérebro biológico.

## 4.2 Propriedades das Redes Neurais Artificiais

As redes neurais artificiais devem o seu poder computacional a duas características principais. Primeiro, sua estrutura paralela e distribuída. Segundo, sua habilidade de aprender e conseqüentemente de generalizar. A generalização refere-se ao fato de uma rede neural produzir saídas adequadas para entradas que não fizeram parte do conjunto de treinamento (aprendizagem). Essas duas propriedades de processamento de informação tornam possível para as redes neurais tratarem de forma vantajosa problemas complexos (de grande escala) que são atualmente intratáveis. Na prática, as redes neurais não são utilizadas isoladamente para fornecer uma solução, o problema é decomposto em diversas subtarefas para as quais as redes neurais possam ser bem aplicadas. Outras propriedades das redes neurais são enumeradas a seguir (HAYKIN,2000):

- Não linearidade: Uma rede neural formada por neurônios não lineares permite efetuar relacionamentos não lineares entre entradas e saídas.
- Mapeamento de entrada-saída: a aprendizagem supervisionada, ou aprendizagem com um “professor”, envolve a modificação dos pesos sinápticos de uma rede neural pela aplicação de um conjunto de amostras de treinamento rotuladas ou exemplos da tarefa. Cada exemplo consiste de um sinal de entrada único e de uma resposta desejada correspondente. Apresenta-se para a rede um exemplo escolhido ao acaso do conjunto, e os pesos sinápticos (parâmetros livres) da rede são modificados para minimizar a diferença entre a resposta desejada e a resposta real da rede, produzida pelo sinal de entrada, de acordo com um critério estatístico apropriado. O treinamento da rede é repetido por muitos exemplos do conjunto até que a rede alcance um estado estável onde não haja mais modificações significativas nos pesos sinápticos. Os exemplos de treinamento previamente aplicados podem ser reaplicados durante a sessão de treinamento, mas em uma ordem diferente. Assim, a rede aprende dos exemplos ao construir um mapeamento entrada-saída para o problema considerado.
- Adaptabilidade: as redes neurais tem uma capacidade inata de adaptar seus pesos sinápticos a modificações do meio ambiente. Em particular, uma rede neural treinada

para atuar em um ambiente específico pode ser facilmente retreinada para lidar com pequenas modificações nas condições operativas do ambiente. Além disso, quando está operando em um ambiente não estacionário, uma rede neural pode ser projetada para modificar seus pesos sinápticos em tempo real.

- Resposta a evidências: no contexto da classificação de padrões, uma rede neural pode ser projetada para fornecer informação não somente sobre qual padrão particular selecionar, mas também sobre a confiança ou crença na decisão tomada. Esta informação pode ser utilizada para rejeitar padrões ambíguos, caso eles estejam presentes, e com isso melhorar o desempenho de classificação da rede.
- Tolerância a falhas: uma rede neural, implementada na forma física (em hardware) é inerentemente tolerante a falhas, ou capaz de realizar computação robusta, no sentido de que seu desempenho se degrada suavemente sob condições de operação adversas. Se um neurônio ou suas conexões são danificados, por exemplo, a recuperação de um padrão armazenado é prejudicada em qualidade. Contudo, devido à natureza distribuída da informação armazenada na rede, o dano deve ser extenso para que a resposta global da rede seja degradada seriamente. O que deve ser observado nessas condições é uma degradação suave do desempenho em vez de uma falha seriamente comprometedora.
- Analogia neurobiológica: o projeto de uma rede neural é motivado pela analogia com o cérebro, uma prova real de que processamento paralelo tolerante a falhas é possível, rápido e poderoso. Neurobiologistas veem redes neurais artificiais como ferramentas de pesquisa para a interpretação de fenômenos neurobiológicos. Engenheiros se inspiram na neurobiologia para resolverem problemas complexos que não podem ser resolvidos pelos métodos convencionais.

### 4.3 Modelo de um Neurônio Artificial

O neurônio é a unidade de processamento fundamental da rede neural. Cada neurônio é composto de três unidades básicas, como mostra a figura 6:

1. Um conjunto de sinapses ou conexões, acompanhadas de pesos sinápticos. Cada entrada do neurônio é multiplicada pelo peso sináptico correspondente.
2. Um combinador que gera a soma de todos os sinais de entrada, multiplicados pelos pesos sinápticos correspondentes. Essas operações constituem um combinador linear.
3. Uma função de ativação que é aplicada à saída do combinador linear, resultando na saída final do neurônio. Essa função geralmente limita a amplitude da saída para

intervalos entre  $[0,1]$  ou  $[-1,1]$ . Em alguns casos os neurônios não apresentam função de ativação ou ela é puramente linear, apenas repetindo a saída do combinador.

Um neurônio pode possuir também um *bias*, valor que é adicionado à saída do combinador linear e que também é ajustado durante o treinamento.

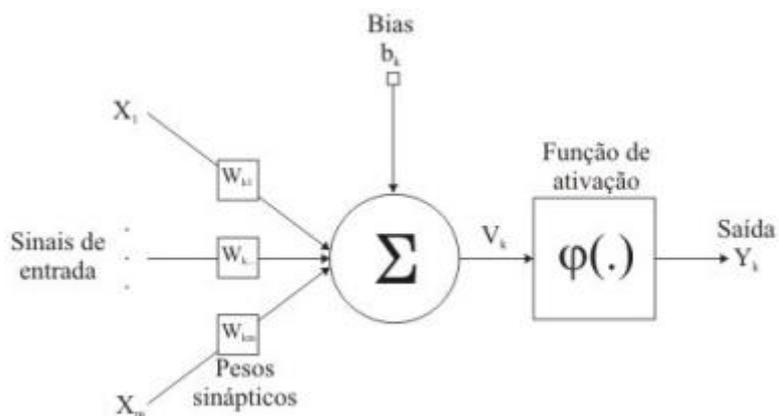


Figura 6 - Modelo de um Neurônio Artificial

As funções de ativação mais comuns são listadas a seguir:

- Função de limiar: assume 1 para valores positivos e 0 para valores negativos.

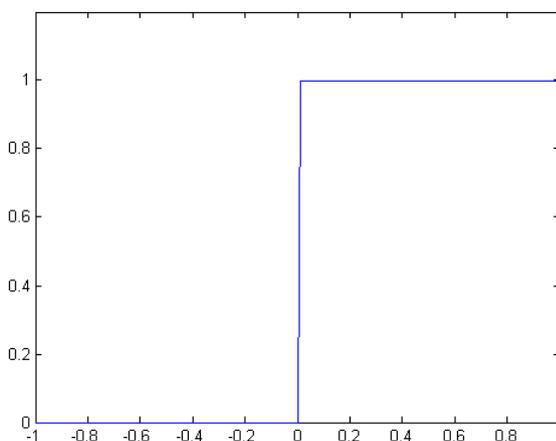


Figura 7 - Função limiar

- Função sigmoide: é definida pela equação

$$\varphi(v) = \frac{1}{1 + e^{-av}}$$

Onde  $a$  é o parâmetro de inclinação da função sigmoide.

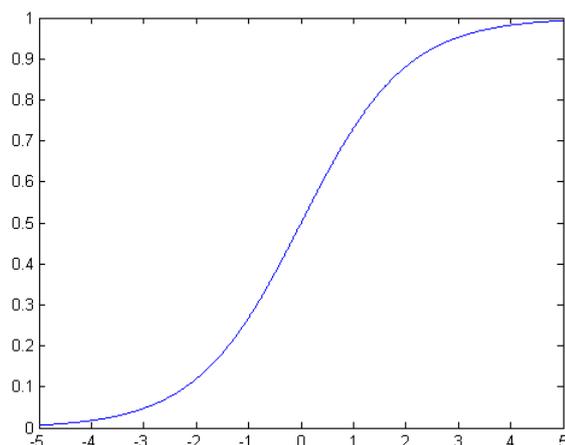


Figura 8 - Função sigmóide com  $\alpha = 1$

- Função tangente sigmoide hiperbólica: é definida pela equação

$$\varphi(v) = \frac{2}{1 + e^{-2v}} - 1$$

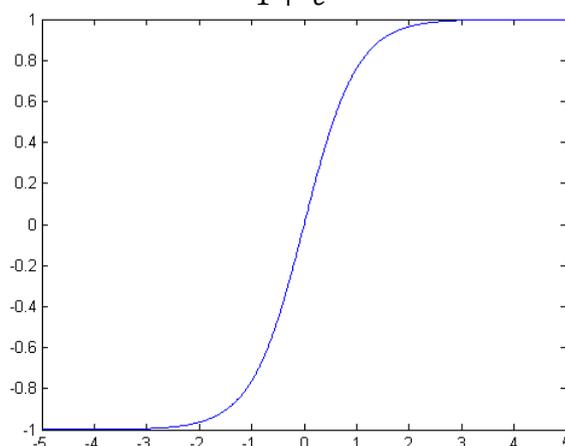


Figura 9 - Função tangente sigmoide hiperbólica

#### 4.4 Perceptron de Múltiplas Camadas

Existem diversas arquiteturas de redes neurais artificiais. Nesse trabalho foram utilizadas as redes conhecidas como perceptrons de múltiplas camadas (*Multi-layer Perceptron* – MLP). Essa arquitetura se caracteriza pelo seu alto grau de conectividade, com neurônios dispostos em uma série de camadas, com pelo menos uma camada oculta e uma camada de saída. Os nós da camada de entrada da rede fornecem os sinais de entrada aos neurônios da primeira camada oculta cujas saídas serão, por sua vez, usadas como entradas dos neurônios da próxima camada, e assim por diante para o resto da rede. O conjunto de sinais de saída dos neurônios da última camada constitui a resposta global da rede. As redes do tipo MLP são conhecidas também como redes alimentadas adiante (*redes feedforward*), pois a informação é propagada em apenas um sentido, da primeira para a última camada. A MLP exibida na figura

10 pode ser definida como uma rede 3-3-2, pois possui duas camadas ocultas com três neurônios cada e uma camada de saída com dois neurônios.

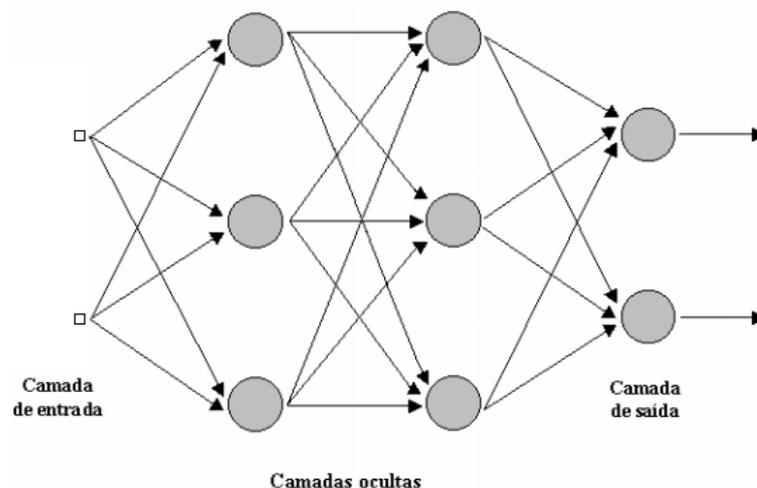


Figura 10 - Perceptron de Múltiplas Camadas com duas camadas ocultas e uma camada de saída

Uma característica importante das redes MLP é a sua capacidade de aproximação universal. Qualquer função contínua pode ser aproximada por uma rede MLP que possua uma camada oculta com funções de ativação sigmoide ou tangente hiperbólica.

O algoritmo *backpropagation* é capaz de treinar redes MLP com diferentes funções de ativação e permite o mapeamento de relações lineares e não lineares entre os vetores de dados de entrada e saída para a solução de problemas de aproximação de funções, classificação de padrões, identificação de sistemas, entre outros. O *backpropagation* é um processo realizado em duas fases. Na primeira fase, as entradas são apresentadas à rede e propagadas até que a saída seja gerada. Essa saída é comparada com a saída desejada, gerando um sinal de erro. Na segunda fase o erro é retropropagado pela rede, e a sua derivada é utilizada para ajustar os pesos sinápticos de modo a reduzir o erro.

Existem diversos algoritmos diferentes que utilizam o *backpropagation* como técnica de treinamento. Esses algoritmos diferem em velocidade de convergência e requisitos computacionais de processamento e de memória. A escolha do algoritmo mais adequado não é trivial e depende da complexidade e da natureza do problema, do tamanho do conjunto de dados disponível para treinamento, do número de parâmetros ajustáveis da rede e do erro mínimo desejado.

O algoritmo de *Levenberg-Marquardt* é o que apresenta convergência mais rápida em redes de tamanho moderado para problemas de aproximação de funções, especialmente quando se deseja uma precisão muito alta. Entretanto, as suas vantagens diminuem quando o

tamanho da rede aumenta, pois a quantidade de memória e de processamento exigida cresce rapidamente. Além disso, esse algoritmo é relativamente fraco em problemas de reconhecimento de padrões. Por outro lado, o algoritmo de retropropagação resiliente requer pouca memória e é o mais rápido para problemas de reconhecimento, mas é ineficiente em problemas de aproximação de funções. Já o algoritmo do gradiente conjugado escalado produz bons resultados para uma grande variedade de problemas, especialmente em redes com uma grande quantidade de pesos, sendo quase tão eficiente quanto o de *Levenberg-Marquardt* para problemas de aproximação de funções e quase tão eficiente quanto o resiliente para reconhecimento de padrões, além de requisitar uma quantidade modesta de memória. O método *Quasi-Newton* BFGS é similar ao de *Levenberg-Marquardt*, mas requer menos memória.

O software matemático *Matlab* dispõe de diversos algoritmos para o treinamento de redes MLP, descritos brevemente na tabela 1 a seguir (Zanata, 2005).

Tabela 1 - Lista de algoritmos de treinamento do *Matlab*

Função	Descrição
<i>traingd</i>	Gradiente descendente básico. Apresenta resposta lenta e pode ser utilizado em treinamentos de modo incremental.
<i>traindm</i>	Gradiente descendente com momento. Geralmente é mais rápido do que o básico. Pode ser utilizado em treinamentos de modo incremental.
<i>trainidx</i>	Gradiente com taxa de aprendizado adaptativa. Convergência mais rápida do que o básico, porém só pode ser utilizado em treinamento de batelada.
<i>trainrp</i>	Retropropagação resiliente. Algoritmo simples de treinamento batelada com rápida convergência e pouca memória requisitada.
<i>traincgf</i>	Algoritmo de gradiente conjugado de <i>Fletcher-Reeves</i> . Possui os menores requisitos de memória dentre os algoritmos de gradiente conjugado.
<i>traincgp</i>	Algoritmo de gradiente conjugado de <i>Polak-Ribière</i> . Requer um pouco mais de memória que o <i>traincgf</i> , porém apresenta convergência rápida para alguns problemas específicos.
<i>traingb</i>	Algoritmo do gradiente conjugado de <i>Powell-Beale</i> . Requer um pouco mais de memória que o <i>traincgp</i> , mas geralmente apresenta uma convergência mais rápida.
<i>trainscg</i>	Algoritmo de gradiente conjugado em escala. Adapta-se com facilidade a uma grande variedade de problemas.
<i>trainbfg</i>	Método <i>Quasi-Newton</i> BFGS. Necessita o armazenamento da aproximação da matriz Hessiana e requer mais recurso computacional a cada iteração do que os algoritmos de gradiente conjugado, porém geralmente converge em poucas iterações.
<i>trainoss</i>	Método <i>one step secant</i> . Meio termo entre métodos de gradiente conjugado e métodos <i>Quasi-Newton</i> .
<i>trainlm</i>	Algoritmo de <i>Levenberg-Marquardt</i> . É o algoritmo de treinamento mais rápido para redes de tamanho moderado. Possui a função de redução de memória para ser utilizada quando possuir muitos dados para treinamento.

<i>trainbr</i>	Regularização de <i>Bayesian</i> . É uma modificação do algoritmo de treinamento de <i>Levenberg-Marquardt</i> para gerar redes com melhor generalização. Reduz a dificuldade de se determinar a arquitetura otimizada.
----------------	---

#### 4.5 Compressão de Dados Utilizando Perceptron de Múltiplas Camadas

A extração das características de conjuntos de dados de entrada de alta dimensão é uma tarefa de fundamental importância em muitas áreas de processamento da informação tais como reconhecimento de padrões, tecnologia e comunicação, telemedicina, análises sísmicas, radar, sonar, etc.. Por outro lado, a eliminação da informação redundante permite que a informação relevante contida no sinal de entrada seja expressa em uma dimensão de ordem inferior. Como resultado, o armazenamento, a transmissão e o processamento da informação, não apenas em *software* como também em *hardware*, torna-se mais simples devido à redução da dimensionalidade. A importância de se obter uma compressão de dados é uma realidade, basta ter em mente os campos de aplicação que requerem um contínuo e elevado volume de dados a serem armazenados tais como o armazenamento de imagens realizadas por exames médico-hospitalares, controles de trânsito, sensoriamento remoto, etc. (SOUZA, 1998). Nesta seção é descrita como uma rede neural do tipo perceptron de múltiplas camadas pode ser utilizada para efetuar a redução da dimensionalidade de um conjunto de dados de entrada.

As unidades ocultas de uma rede MLP treinada com o *backpropagation* carregam um importante papel na operação da compressão, agindo como detectores de fatores significantes que caracterizam padrões de entrada de interesse. O processo de treinamento pode ser desenvolvido sem um professor externo, de forma que a extração de fatores é desenvolvida sem conhecimento detalhado do padrão de saída. Uma das formas mais simples de se evitar a necessidade de um professor externo no treinamento é treinar um mapeamento de identidade sobre todo o conjunto de entradas. Para isto, treina-se a rede com o conjunto de saída desejado sendo exatamente igual ao conjunto de entrada, como ilustra a figura 11.

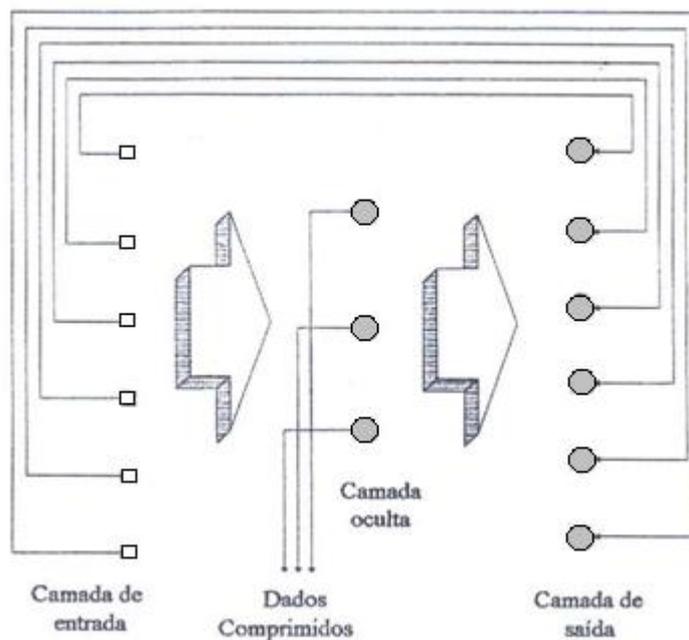


Figura 11 - Rede autoassociativa com uma única camada oculta

A rede treinada nessa condição deve reconstruir o melhor possível os vetores de entrada, realizando o mapeamento de identidade através da sua camada oculta. Assim, a rede é forçada a desenvolver uma codificação eficiente naquela camada, cujo número de neurônios é mais baixo do que a dimensão dos vetores da entrada, gerando uma saída de menor dimensão. Existem dois aspectos interessantes nesta operação:

1. A rede desenvolve uma representação compacta de seu ambiente (codificação);
2. A representação é aprendida de maneira autossupervisionada.

A rede neural depois de treinada pode ser dividida em duas partes. A primeira parte constitui a rede compressora, cuja última camada é denominada de camada de representação, pois representa de forma compactada o conjunto de entrada. A segunda parte, como mostra a figura 12, constitui a rede reconstrutora, cuja última camada, que é a saída da rede como um todo, é capaz de reconstruir os dados originais através dos dados codificados pela primeira parte.

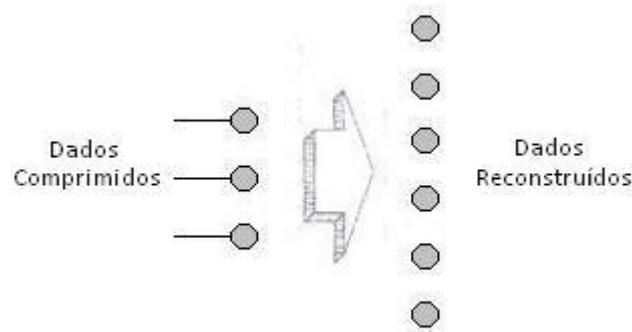


Figura 12 - Rede reconstrutora (descompressora)

Um perceptron de múltiplas camadas operando de modo autossupervisionado é referido como um autoassociador ou autocodificador. Basicamente, tal estrutura computa os principais componentes dos dados de entrada, o que estabelece uma base ótima para redução da dimensionalidade linear, ou seja, compressão de dados.

A adição de um par de camadas ocultas, uma entre a camada de entrada e a camada de representação e a outra entre a camada de representação e a camada de saída, como na figura 13, permite que o autoassociador desenvolva representações não lineares dos dados. Desta forma, será necessário um número menor de nós na camada de representação e, com isto, uma compressão de dados mais efetiva pode ser desenvolvida do que quando comparada ao caso do autoassociador com uma única camada oculta (SOUZA, 1998).

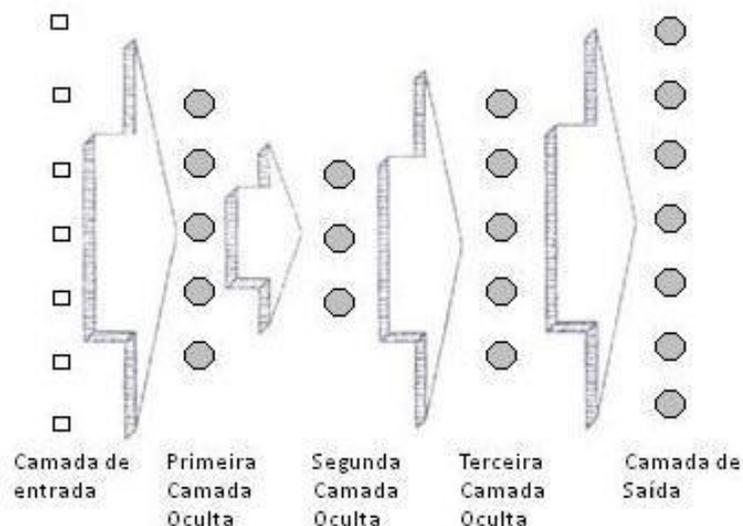


Figura 13 - Autoassociador com três camadas ocultas

A taxa de compressão obtida com o uso de redes MLP compressoras depende da necessidade da aplicação. Pode ser desejada uma elevada taxa de compressão, porém sem haver muito compromisso com a qualidade dos dados resultantes e vice-versa. As redes MLP

são muito versáteis nesse sentido, permitindo fazer uma relação do tipo custo/benefício da maneira desejada, pois a taxa de compressão e qualidade dos dados varia dependendo do número de neurônios na camada de representação e do número de camadas ocultas.

## 5. Metodologia

### 5.1 Proposta do Trabalho

A proposta deste trabalho consiste no desenvolvimento de um sistema capaz de monitorar o nível da deposição na Unidade de Destilação Atmosférica U-270. O sistema consistirá basicamente de uma rede neural artificial do tipo perceptron de múltiplas camadas treinada de forma autoassociativa para realizar uma análise de componentes principais, ou seja, uma compressão ou redução da dimensionalidade de dados. A rede neural deverá receber na sua entrada variáveis de processo da Unidade, extrair informação e reduzir a dimensionalidade dessas variáveis e exibir na sua saída uma curva que serve como uma indicação da deposição.

### 5.2 Coleta e Análise de Dados

A primeira etapa para o desenvolvimento de um sistema capaz de monitorar o nível da deposição na Unidade de Destilação é selecionar variáveis do processo que possivelmente são influenciadas pelo problema. O sistema fará uso da informação contida nestas variáveis para indicar a deposição. Esta tarefa requer o compartilhamento da informação entre o projetista e os operadores da planta, que conhecem bem a sua dinâmica e são capazes de indicar quais são as variáveis mais importantes para o objetivo proposto. Algumas das variáveis escolhidas podem ser descartadas posteriormente, se análises mostrarem que elas são desnecessárias.

Os dados coletados devem ser investigados para que sejam detectados e tratados valores espúrios ou períodos de perda de dados, causados por problemas na medição ou nos sistemas de transmissão ou outras perturbações. Filtros digitais devem ser utilizados para reduzir ruídos e outros efeitos temporários.

Os dados armazenados nos bancos de dados de plantas industriais são gerados a partir de amostras dos sinais medidos pelos instrumentos. Em geral, os técnicos das plantas são conservadores quanto ao tempo de amostragem, devido à grande memória de armazenamento disponível, o que resulta em dados armazenados com um período de amostragem muito menor do que o necessário para respeitar o teorema de *Nyquist*. Nesses casos, é interessante subamostrar os dados para evitar o manuseio de conjuntos de dados muito grandes e, principalmente, reduzir a colinearidade dos dados, ou seja, evitar que uma série de pontos consecutivos apresentem o mesmo valor.

É comum que os dados de uma planta apresentem magnitudes diferentes, dependendo da unidade escolhida e da natureza do processo. Isso pode fazer com que variáveis de maior magnitude se tornem dominantes sobre as variáveis de baixa magnitude durante, por exemplo, o processo de aprendizagem de uma rede neural. Por esse motivo, é necessário normalizar os dados antes de utilizá-los.

Para analisar o efeito da deposição na refinaria, foram selecionadas variáveis de pressão, temperatura, vazão e nível em locais estratégicos da U-270, escolhidas a partir do relato dos operadores e de uma análise dos fluxogramas do processo. Os dados foram obtidos em parceria com a Petrobras no banco de dados do *Plant Information* (PI), um sistema utilizado pela empresa para manter um histórico dos valores medidos pelos instrumentos de campo. O *Plant Information* utiliza o protocolo OPC para se comunicar com o sistema supervisor da refinaria, que por sua vez se comunica diretamente com os Controladores Lógicos Programáveis que recebem os sinais de medição enviados pelos instrumentos de campo. Os dados foram coletados com um tempo de amostragem de um minuto, de janeiro até setembro de 2009, totalizando 393120 pontos para cada variável.

Os dados obtidos apresentam muito ruído e valores espúrios. Assim, para facilitar a análise, os dados foram tratados com dois filtros em sequência, sendo o primeiro deles um filtro de média móvel simples e o segundo deles um filtro de limites. O filtro da média móvel é um filtro digital de resposta ao impulso finita (FIR) utilizado para reduzir o ruído, e consiste simplesmente em substituir cada ponto pela média de uma janela de pontos, como mostra a equação:

$$y(k) = \frac{x(k) + x(k-1) + x(k-2) + \dots + x(k-M)}{M}$$

Foram realizados testes variando-se o tamanho da janela entre 100 e 1000 pontos, sendo obtidos bons resultados com uma janela de 500 pontos para a maioria das variáveis e de 1000 pontos para algumas variáveis mais ruidosas. O segundo filtro foi utilizado para cancelar os valores espúrios que tendem ou a infinito ou a zero. Esse filtro basicamente estabelece um intervalo para o qual o valor da variável é aceitável, substituindo os pontos que estão fora desse intervalo pelos pontos imediatamente anteriores. Ambos os filtros foram executados com o auxílio do *Matlab*. As figuras a seguir mostram a evolução da curva da temperatura do medidor TI-03 após a aplicação dos filtros.

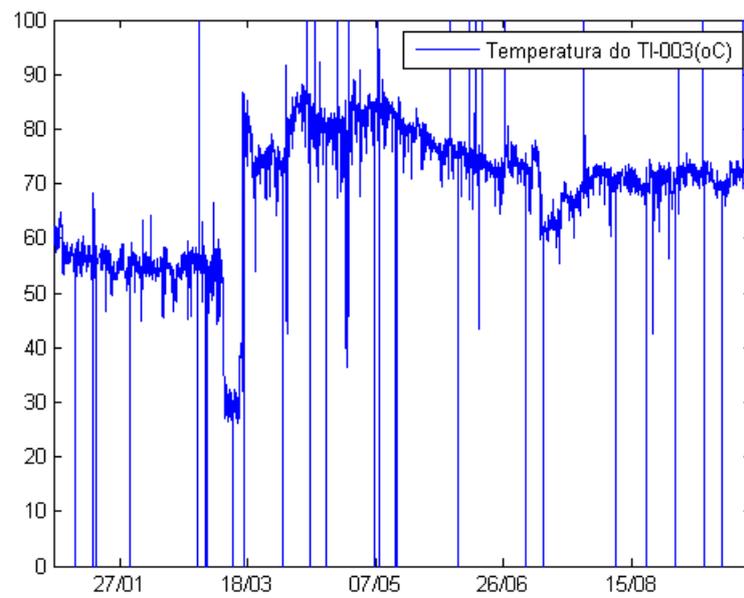


Figura 14 - Curva original do TI-03

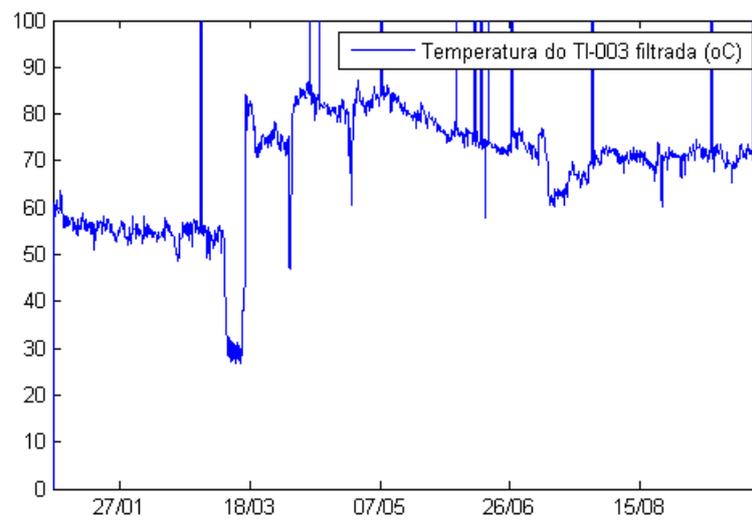


Figura 15 - Curva do TI-03 após aplicação do filtro da média móvel

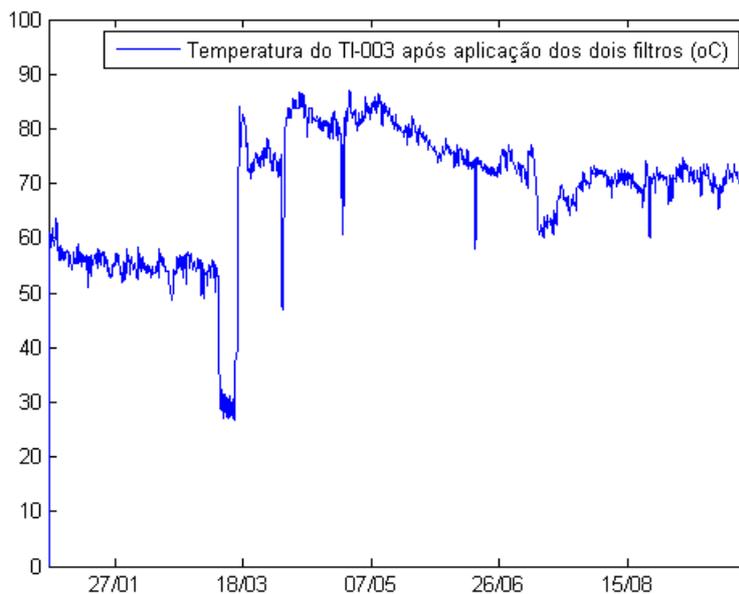


Figura 16 – Curva do TI-03 após a aplicação do filtro da média móvel e dos limites

De posse dos dados filtrados e sabendo-se que a parada para manutenção do processo ocorreu no período de 8 a 15 de março de 2009, foi possível estabelecer uma comparação entre o comportamento do sistema antes e depois da parada, como mostra a tabela 2.

Tabela 2 - Variáveis coletadas e comentários relativos à parada

Variável	Descrição	Comentários com relação à parada	Média antes	Média depois	Variância antes	Variância depois
TI-02	Temperatura da carga bruta de óleo para a unidade a jusante do P-27001	Não sofreu nenhuma alteração com a parada.	55.16	55.43	4.02	7.1
TI-03	Temperatura carga bruta de óleo para a unidade a jusante do P-27002	Aumentou de temperatura após a parada. O P-27002 recebe diretamente da região de maior contaminação (prato 13), e sofre maior incrustação.	55.21	74.39	9.2	34.25
TI-04	Temperatura da carga bruta de óleo para a unidade a jusante do P-27003	Aumentou um pouco após a parada. O P-27003 sofre leve deposição.	109.47	124.24	48.58	58.2
TI-05	Temperatura da carga bruta de óleo para a unidade a jusante do P-27004	Aumenta de temperatura por aproximadamente 2 meses, depois caindo novamente.	145.92	144.29	51.75	117.12
TI-12	Temperatura da saída de querosene do trocador calor P27001	Diminui um pouco mas aumenta ao longo dos meses.	118.02	115.01	47.21	76.74

TI-14	Temperatura da saída de querosene do trocador calor P27002	Sofreu um grande aumento após a parada.	34.85	103.31	125.38	165.22
TI-15	Temperatura do óleo diesel do trocador de calor P27003 A	Aumentou um pouco após a parada.	78.99	92.66	19.29	44.86
TI-20	Temperatura de saída de resíduo atmosférico do trocador P27004 A	Aumentou muito pouco.	130.44	135.78	41.83	57.48
TI-22	Temperatura da carga bruta de óleo para a unidade a montante do P-27001	Não sofreu alteração.	47.99	48.03	7.37	4.55
TI-50	Temperatura de saída dos vapores no topo da torre	Diminuiu um pouco, com um grande aumento em julho.	113.94	108.01	26.61	63.84
TI-53	Temperatura do RAT da base da torre T-270001	Não sofreu alteração.	367.4	369.83	329.04	316.87
TI-63	Temperatura de retorno de querosene para a coluna T-27002	Não sofreu alteração.	197.65	190.31	99.02	132.9
TI-64	Temperatura do retorno de óleo diesel para a coluna T-27003	Não sofreu alteração. Períodos de aumento entre julho e setembro.	277.17	278.37	186.6	201.69
TI-66	Temperatura do óleo diesel da coluna T27003 refulvedor P27010	Não sofreu alteração visível, possui grande variação.	240.44	241.47	391.16	732.82
TI-71	Temperatura de saída do querosene da coluna T27002	Quase nenhuma alteração.	185.26	187.07	88.75	45.58
TI-43	Temperatura na saída de refluxo de diesel	Aumentou um pouco após a parada, com um grande aumento em julho.	185.24	195.78	80.42	119.07
FI-18	Vazão de reciclo da nafta no proveniente do vaso V-27001	Diminuiu um pouco.	39.33	32.07	16.85	30.08
FI-21	Vazão de refluxo de diesel a montante da torre	Possui grande variação.	29	28.58	31.66	11.75
FI-23	Vazão de óleo térmico a jusante do P-27009	Variável muito ruidosa, mas diminuiu um pouco. Grande queda em julho.	17.44	15.54	22.69	32.04
FI-22	Vazão de refluxo	Estava zerada antes da parada.	0.09	32.46	1.88	95.23

	de querosene a montante da torre	Grande queda em julho.				
FI-24	Vazão de resíduo atmosférico a montante do P-27010	Não sofreu alteração.	0.023	0.024	0	0
LI-16	Nível de carga na torre T-270001	Não sofreu alteração. Diminuiu o ruído.	49.92	46.63	4.91	32.5
LI-19	Nível do vaso de topo da torre atmosférica V27001	Diminui imediatamente após a parada mas se altera em períodos diferentes.	54.95	51.66	3.15	18.41
LI-31	Nível da corrente de querosene para retificação a jusante da torre	Não sofreu alteração. Muito ruidosa.	52.71	49.22	28.24	42.13
LI-33	Controle de nível no fundo da torre T-27003	Não sofreu alteração.	49.6	50.38	22.54	17.08
PI-28	Pressão do produto de topo da torre T-27001	Diminui após a parada, mas cresceu e caiu novamente.	0.52	0.43	0	0.01
PDI-27	Pressão da corrente de querosene proveniente da torre de destilação	Aumentou após a parada, mas caiu e cresceu novamente.	0.1	0.17	0	0.01
AIBB-02	BSW da carga de óleo dessalgado para unidade a jusante da DL-27001B	Não sofreu alteração devido à parada.	0.97	0.9	0.19	0.05

### 5.3 Desenvolvimento do Sistema Indicador da Deposição

Para o desenvolvimento do sistema indicador da deposição foram escolhidas quatro variáveis de temperatura que apresentaram grande variação depois da parada, sendo elas as medidas pelos TI-03, TI-04, TI-14 e TI-15. Essas temperaturas estão diretamente relacionadas aos trocadores de calor P-27002 e P-27003, que por experiência dos operadores são uns dos principais indicadores da deposição na coluna. O objetivo do sistema é, a partir destas quatro curvas, gerar uma única curva que evidencie o nível da deposição que degrada o processo, a partir da aplicação de um PCA não linear para reduzir a dimensionalidade dos dados. O PCA é realizado utilizando-se uma rede neural artificial que recebe como entrada as quatro curvas de temperatura e deve exibir na saída as mesmas quatro curvas, podendo depois de treinada ser partida em duas redes, sendo uma compressora e outra descompressora. A rede compressora recebe na entrada as quatro curvas originais e possui na saída um número de neurônios menor

que o número de entradas, gerando uma versão comprimida dos dados. A rede descompressora deve receber os dados comprimidos e fornecer na saída as curvas originais, com o menor erro possível. A rede descompressora é utilizada apenas para validar o treinamento da rede, garantindo que os dados fornecidos pela rede compressora realmente representam os dados de entrada. Depois de treinada e validada, apenas a rede compressora é utilizada pelo sistema, para gerar a curva indicadora da deposição.

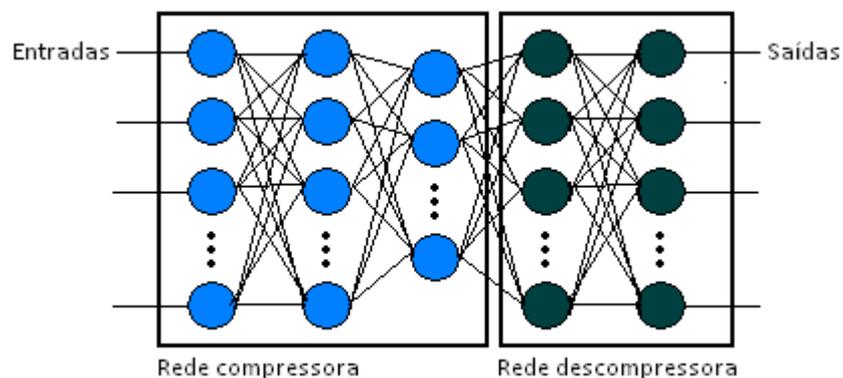


Figura 17 - Rede neural para compressão de dados

Para cada uma das quatro curvas de temperatura é formada uma janela com  $k$  amostras consecutivas da variável, de forma que a dimensão total do conjunto de entrada é de  $4 \times k$ . Neste trabalho foram formadas janelas com 2, 4, 10 e 16 amostras, gerando conjuntos de entrada de 8, 16, 40 e 64 dimensões.

A figura 18 a seguir exemplifica o processo de formação do conjunto de entrada a partir de janelas com 4 amostras por variável, totalizando 16 entradas. Nesse exemplo, as janelas são formadas também com uma sobreposição de 2 amostras.

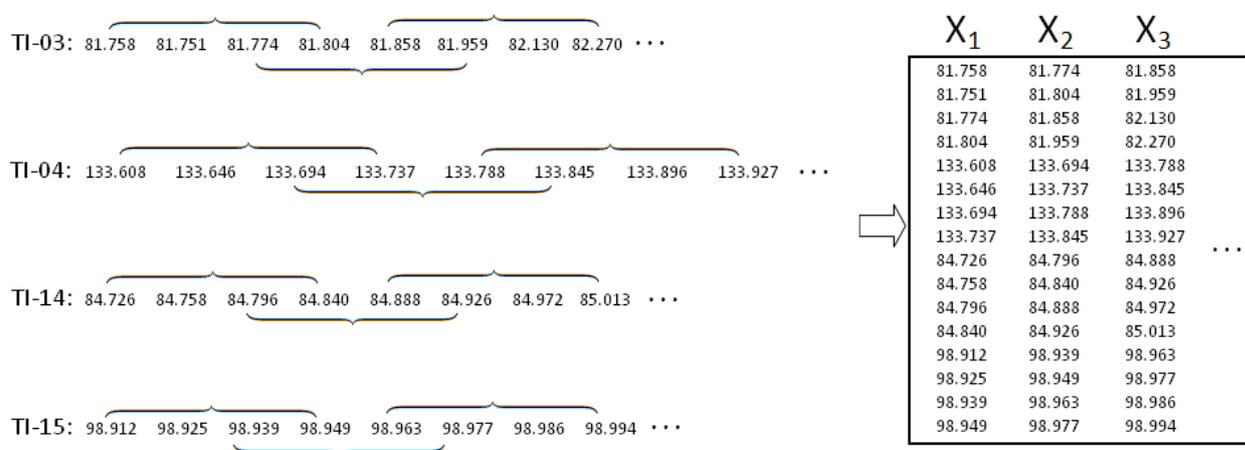


Figura 18 - Exemplo de formação do conjunto de entrada para a rede

As curvas originais, com tempo de amostragem de 1 minuto, foram subamostradas para gerar curvas com tempo de amostragem de 2 e 10 minutos, para diminuir o tamanho do conjunto de treinamento. A média e variância das curvas sofreu pouca alteração após o processo de subamostragem, constatando-se que a informação não foi prejudicada.

Nesse trabalho foram treinadas, com o auxílio do *Matlab*, diversas redes com diferentes combinações de números de camadas, números de neurônios, número de entradas e tempo de amostragem das curvas. O algoritmo de treinamento utilizado foi na maioria dos casos o gradiente conjugado escalado, sendo usado também o método *Quasi-Newton* em casos onde o gradiente não gerou bons resultados. Esses algoritmos são recomendados pelo *Matlab* para serem usados em casos de redes com muitas camadas e um conjunto de treinamento muito grande, pois são os mais eficientes dentre os algoritmos que possuem baixo consumo de memória.

O conjunto de treinamento é normalizado para valores entre -1 e 1 antes de ser apresentado à rede, para aumentar a eficiência da aprendizagem. De todo o conjunto de entrada formado, 60% foi utilizado para treinamento, 20% para validação e 20% para teste. A próxima seção descreverá os resultados obtidos por algumas das redes treinadas nessa etapa.

## 6. Resultados Obtidos

Inicialmente o treinamento foi realizado a partir do conjunto de dados com um período de amostragem de 10 minutos, utilizando janelas de 10, 4 e 2 amostras, formando vetores de entrada de dimensão 40, 16 e 8. A tabela 3 a seguir lista algumas das arquiteturas treinadas e o erro obtido. Uma arquitetura de 40:20:10:20:40 denota uma rede MLP com 40 neurônios na primeira camada oculta (camada que recebe o vetor de entrada), três camadas ocultas com 20, 10 e 20 neurônios cada e uma camada de saída com 40 neurônios.

**Tabela 3 - Redes treinadas para os dados com um período de amostragem de 10 minutos**

Arquitetura	Número de entradas	Número de saídas na camada de representação	Erro de treinamento
40:20:10:20:40	40	10	$7.99 \times 10^{-5}$
40:20:10:10:20:40	40	10	$1.00 \times 10^{-2}$
40:60:10:60:40	40	10	$5.26 \times 10^{-5}$
40:20:4:20:40	40	4	$1.14 \times 10^{-3}$
40:60:30:1:30:60:40	40	1	$1.90 \times 10^{-3}$
16:20:4:20:16	16	4	$2.31 \times 10^{-4}$
16:8:4:8:16	16	4	$2.93 \times 10^{-5}$
16:16:1:16:16	16	1	$2.62 \times 10^{-3}$
8:4:2:4:8	8	2	$1.58 \times 10^{-4}$

Apesar da maioria das redes treinadas nesse caso fornecerem saídas de dimensão bem reduzidas, capazes de representar com boa exatidão o conjunto de entrada, as saídas não podem ser agrupadas para formar uma única curva, pois apresentam comportamento e amplitudes bem diferentes. A exceção é para os casos onde há apenas uma saída na camada de representação. Esta única saída pode então ser usada como a curva indicadora da deposição, objetivo do trabalho.

Os gráficos a seguir ilustram a curva de treinamento, a curva de saída da camada de representação e as curvas de temperatura reconstruídas para a rede 16:16:1:16:16. As curvas reconstruídas servem apenas para validar a rede, comprovando que a curva de saída da camada de representação realmente contém informações extraídas das curvas originais.

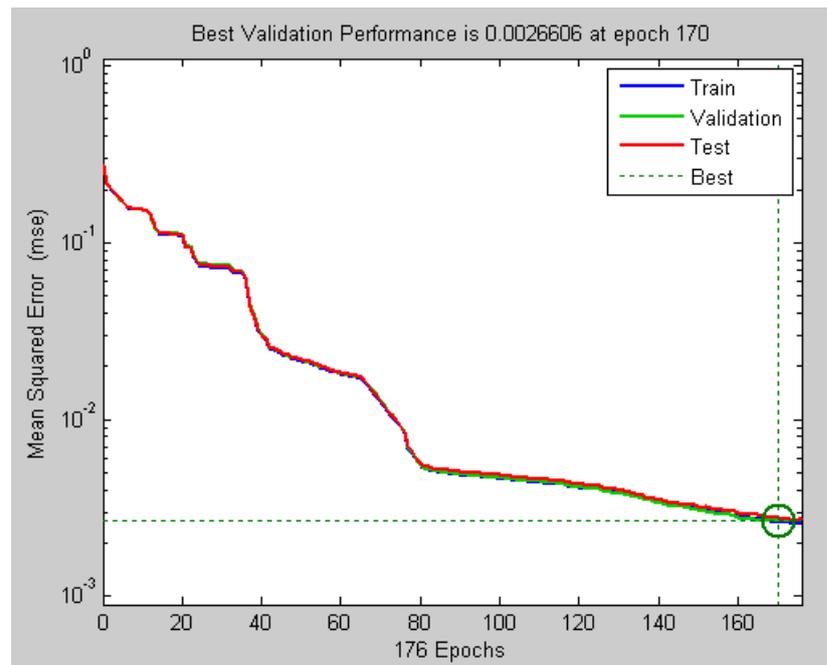


Figura 19 - Erro de treinamento para a rede 16:16:1:16:16

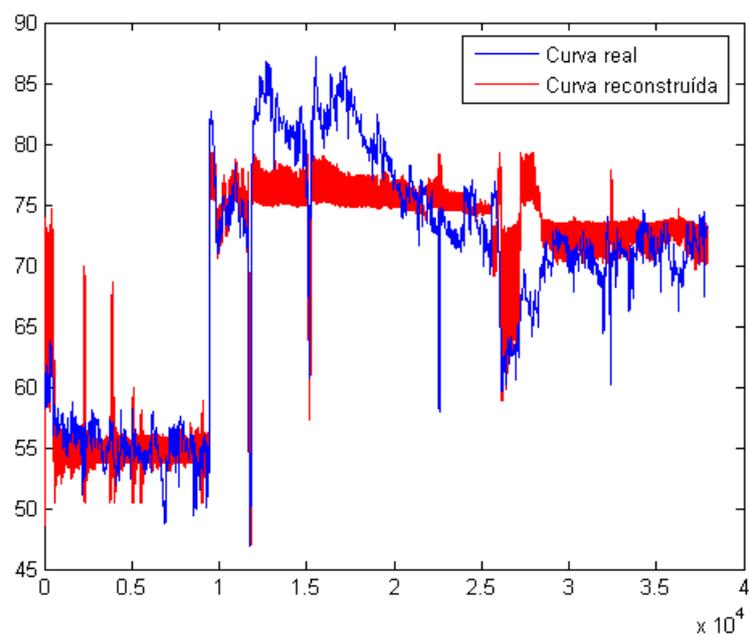


Figura 20 - Curva reconstruída do TI-03 pela rede 16:16:1:16:16

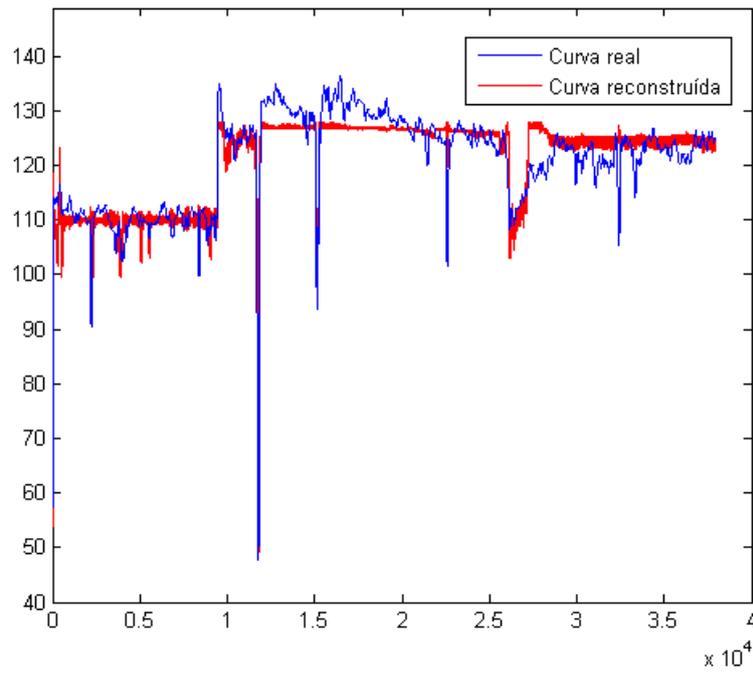


Figura 21 - Curva reconstruída do TI-04 pela rede 16:16:1:16:16

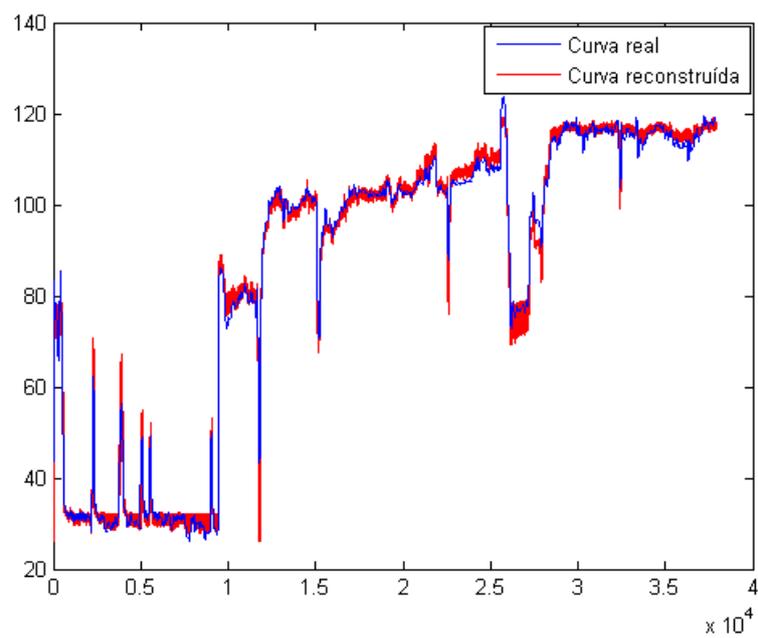


Figura 22 - Curva reconstruída do TI-14 pela rede 16:16:1:16:16

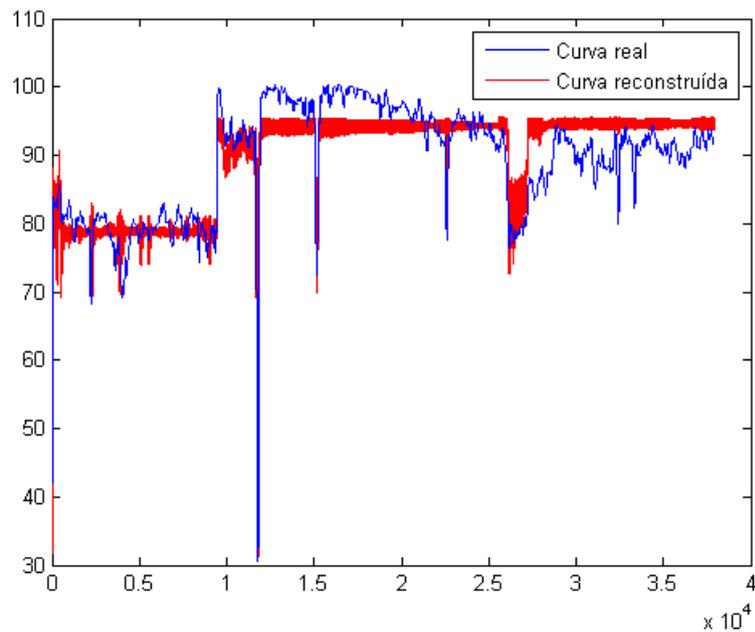


Figura 23 - Curva reconstruída do TI-15 pela rede pela rede 16:16:1:16:16

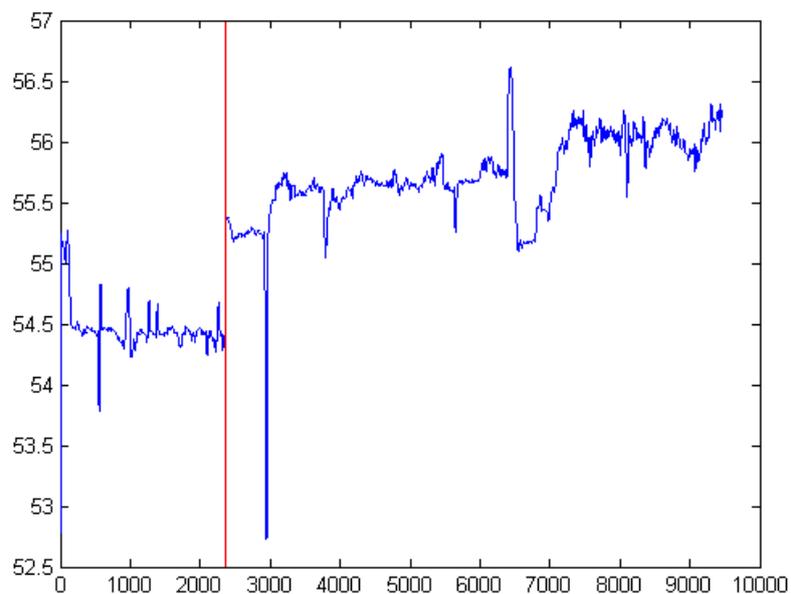


Figura 24 - Curva de saída da camada de representação da rede 16:16:1:16:16. A linha vermelha indica o momento da parada para manutenção.

As curvas reconstruídas pela rede para o TI-03, TI-04 e TI-15 apresentaram erros significativos em alguns instantes, principalmente no período após a parada, mas em geral o comportamento das curvas foi mantido. Já a curva do TI-14 foi reconstruída quase sem erros.

A curva de saída da rede 16:16:1:16:16 aumenta de valor logo após a parada do processo para manutenção. Essa curva poderia ser monitorada em tempo real para indicar a deposição nos equipamentos, assumindo valor médio de aproximadamente 54.5 quando há uma grande deposição e aproximadamente 55.7 quando não há deposição.

Outras redes foram treinadas a partir do conjunto de dados com um período de amostragem de 2 minutos, utilizando janelas de 2, 4 e 16 amostras, formando vetores de entrada de dimensão 8, 16 e 64. A tabela 4 a seguir lista algumas das arquiteturas treinadas e o erro obtido.

**Tabela 4 - Redes treinadas para os dados com um período de amostragem de 2 minutos**

Arquitetura	Número de entradas	Número de saídas na camada de representação	Erro de treinamento
16:8:4:8:16	16	4	$2.86 \times 10^{-4}$
64:32:16:32:64	64	16	$7.28 \times 10^{-5}$
64:32:4:32:64	64	4	$2.47 \times 10^{-4}$
16:8:2:8:16	16	2	$4.86 \times 10^{-3}$
16:4:16	61	4	$2.39 \times 10^{-3}$
8:4:2:4:8	8	2	$1.00 \times 10^{-2}$
64:32:1:32:64	64	1	$5.67 \times 10^{-3}$
16:8:4:8:16	16	4	$4.09 \times 10^{-4}$
16:16:1:16:16	16	1	$1.86 \times 10^{-3}$

Assim como para o caso anterior, apesar das redes fornecerem saídas de dimensão bem reduzidas, capazes de representar com boa exatidão o conjunto de entrada, as saídas não podem ser agrupadas para formar uma única curva, pois apresentam comportamento e amplitudes bem diferentes. A saída das redes que possuem apenas um neurônio na camada de representação pode então ser usada como a curva indicadora da deposição.

Os gráficos a seguir ilustram a curva de treinamento, a curva de saída da camada de representação e as curvas de temperatura reconstruídas para a rede 64:32:1:32:64.

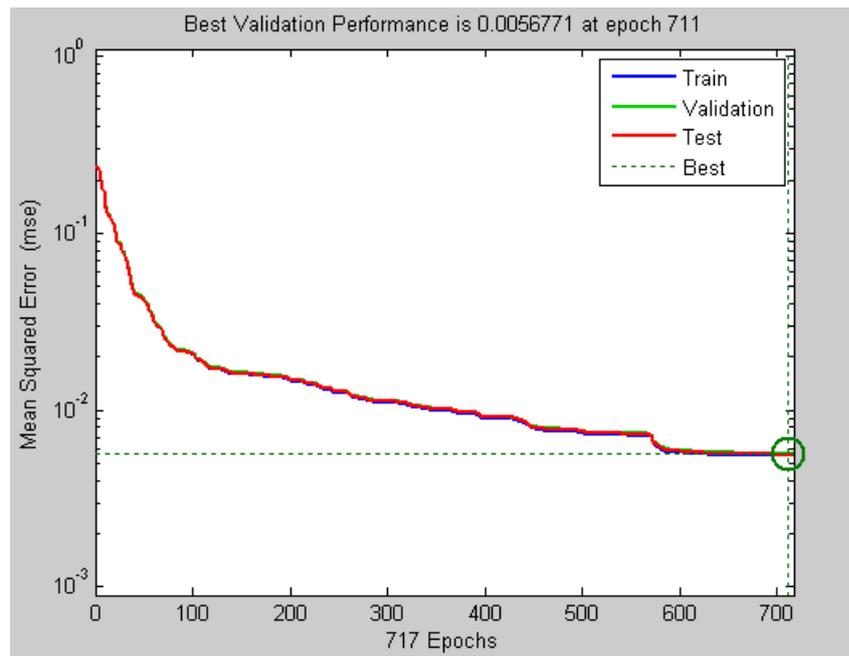


Figura 25 - Erro de treinamento para a rede 64:32:1:32:64

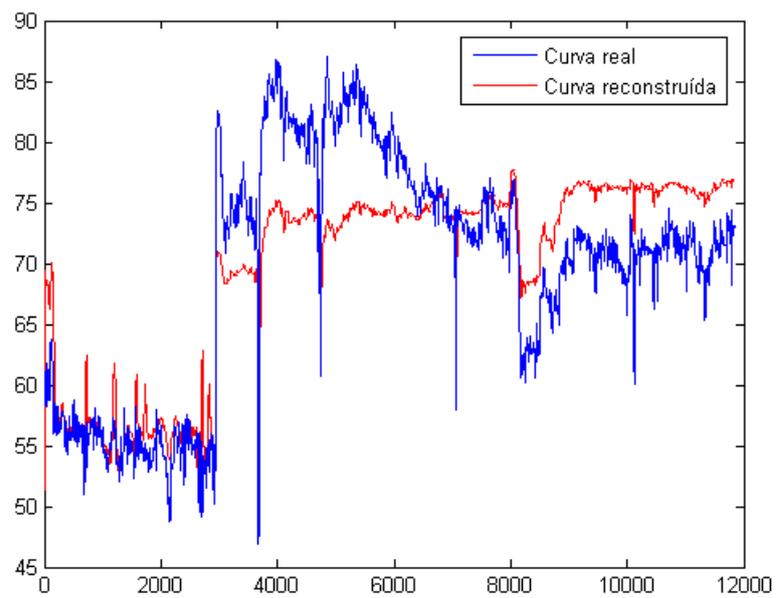


Figura 26 - Curva reconstruída do TI-03 pela rede 64:32:1:32:64

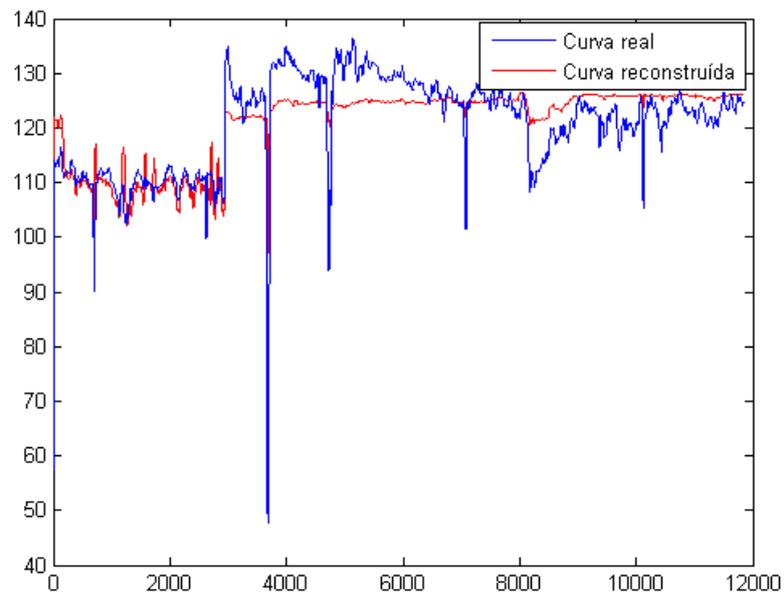


Figura 27 - Curva reconstruída do TI-04 pela rede 64:32:1:32:64

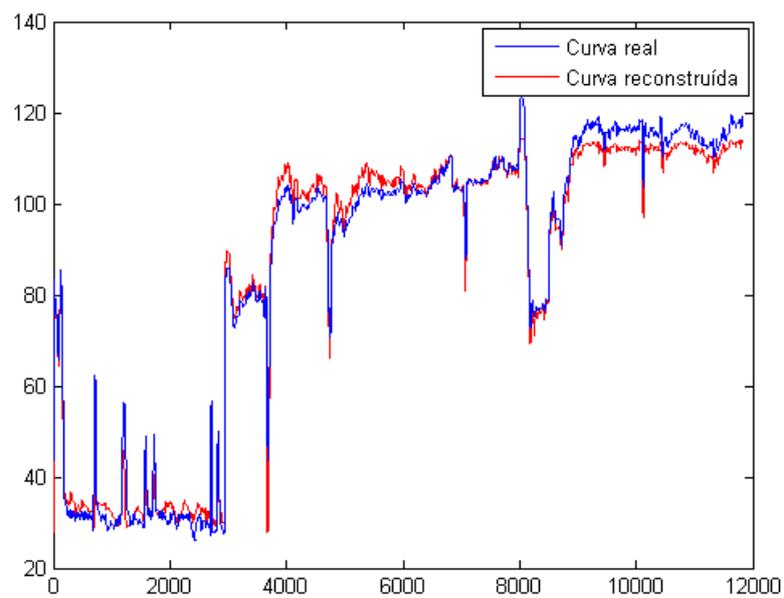


Figura 28 - Curva reconstruída do TI-14 pela rede 64:32:1:32:64

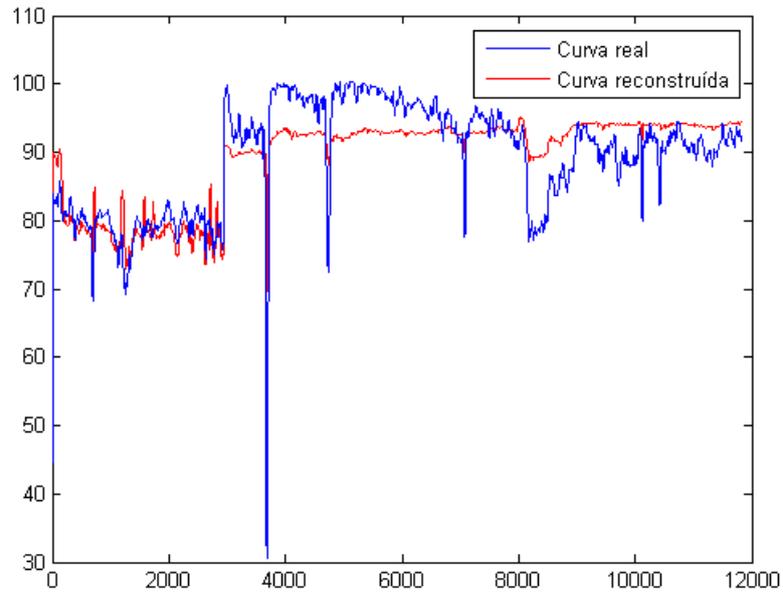


Figura 29 - Curva reconstruída do TI-15 pela rede 64:32:1:32:64

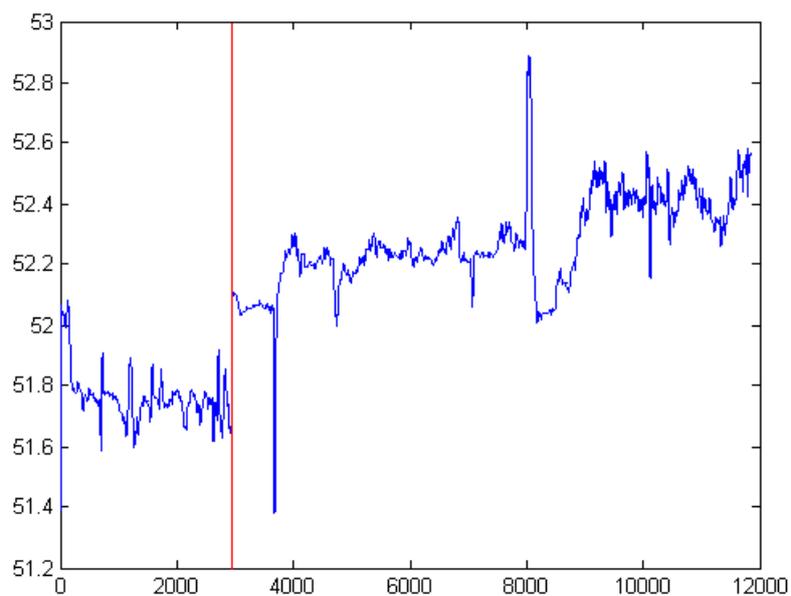


Figura 30 - Curva de saída da camada de representação da rede 64:32:1:32:64. A linha vermelha indica o momento da parada para manutenção.

Esses resultados foram similares aos da rede 16:16:1:16:16 com tempo de amostragem de 10 minutos, mas com erros ainda maiores.

A curva de saída da rede 64:32:1:32:64 também aumenta de valor logo após a parada do processo para manutenção, assumindo valor médio de aproximadamente 51.75 quando há

uma grande deposição e aproximadamente 52.3 quando não há deposição. Esse aumento de valor é menos expressivo que o obtido pelas outras redes.

Os gráficos a seguir ilustram a curva de treinamento, a curva de saída da camada de representação e as curvas de temperatura reconstruídas para a segunda rede 16:16:1:16:16, treinada para os dados com tempo de amostragem de 2 minutos, e que apresentou os melhores resultados.

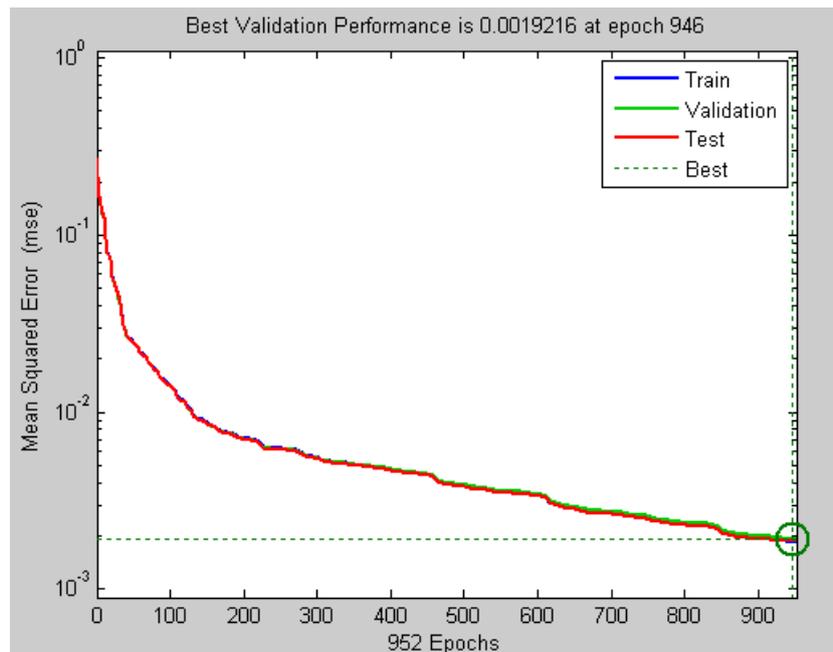


Figura 31 - Erro de treinamento para a rede 16:16:1:16:16 com tempo de amostragem de 2 minutos

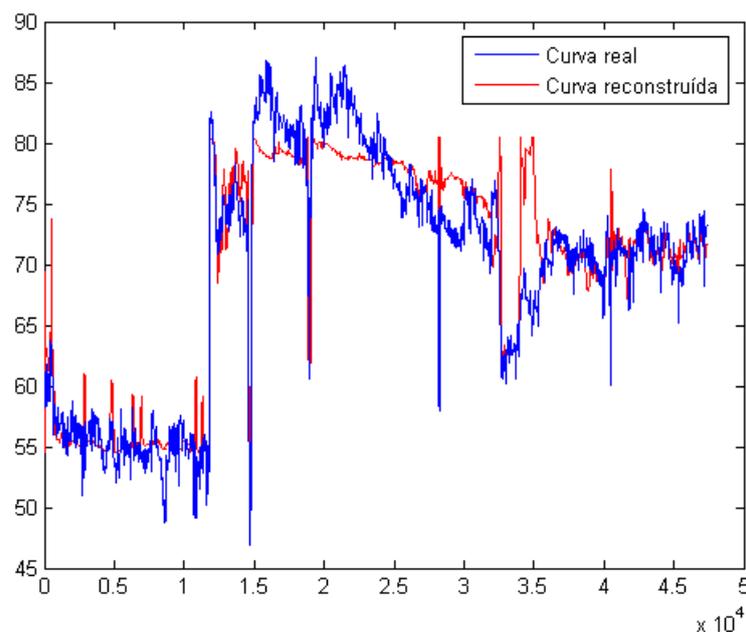


Figura 32 - Curva reconstruída do TI-03 pela rede 16:16:1:16:16 com tempo de amostragem de 2 minutos

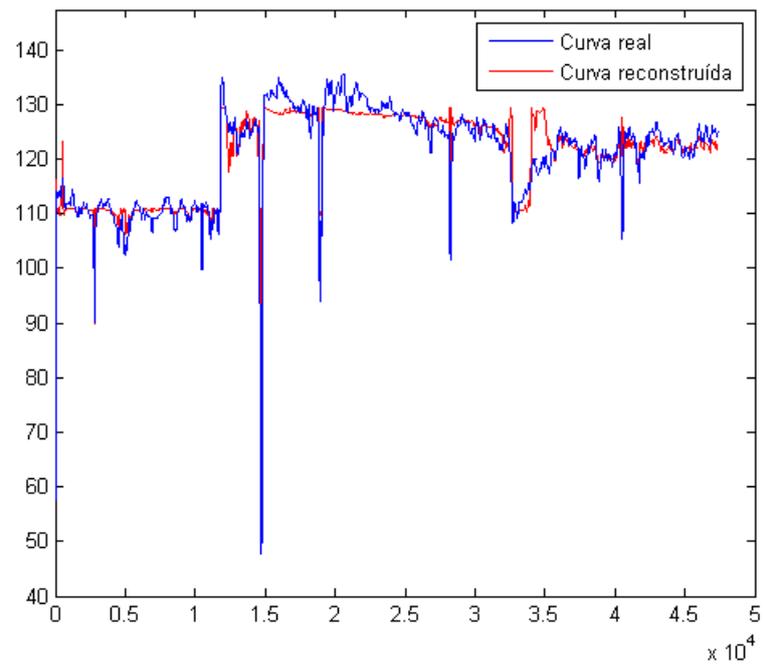


Figura 33 - Curva reconstruída do TI-04 pela rede 16:16:1:16:16 com tempo de amostragem de 2 minutos

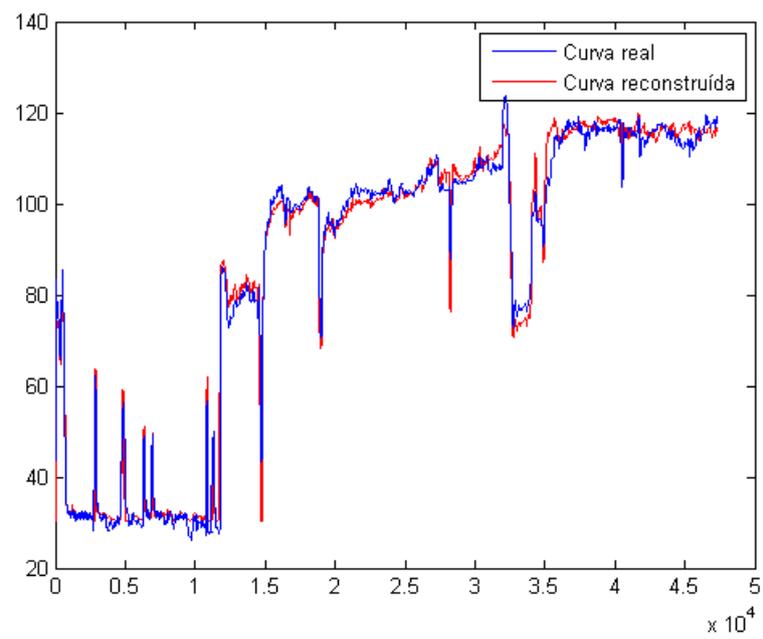


Figura 34 - Curva reconstruída do TI-14 pela rede 16:16:1:16:16 com tempo de amostragem de 2 minutos

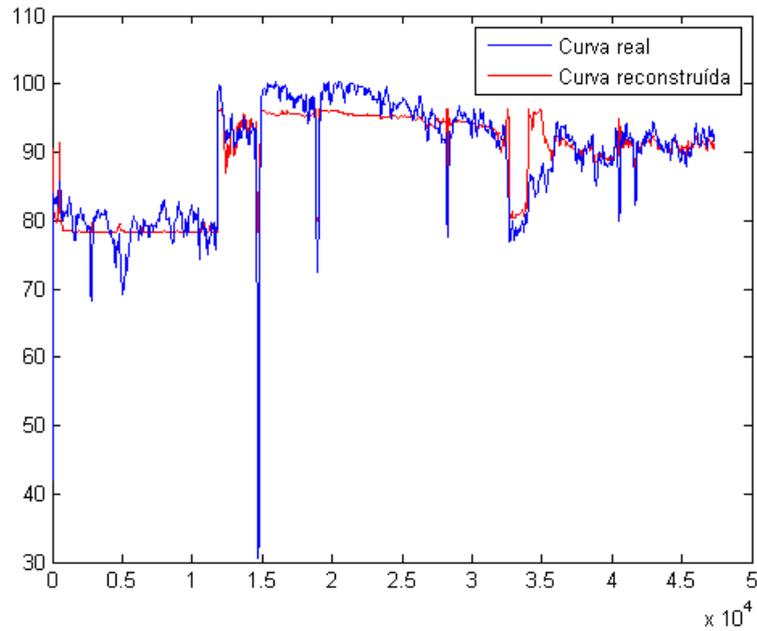


Figura 35 - Curva reconstruída do TI-15 pela rede 16:16:1:16:16 com tempo de amostragem de 2 minutos

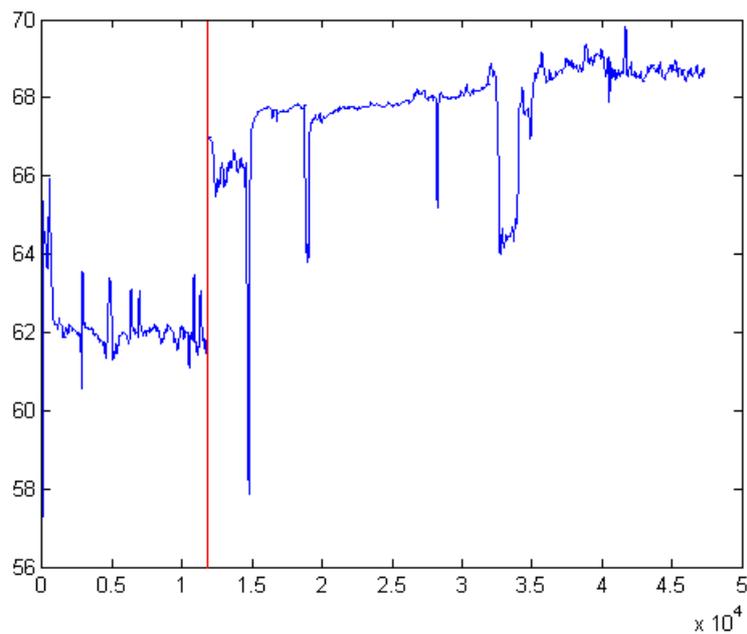


Figura 36 - Curva de saída da camada de representação da rede 16:16:1:16:16 com tempo de amostragem de 2 minutos. A linha vermelha indica o momento da parada para manutenção.

A curva de saída da rede 16:16:1:16:16 foi a que apresentou o aumento mais expressivo após a parada do processo para manutenção, assumindo valor médio de aproximadamente 62 quando há uma grande deposição e aproximadamente 68 quando não há deposição. Dentre as três redes analisadas, essa foi a que apresentou o menor erro de

reconstrução. Dessa forma, essa rede seria a mais indicada para ser utilizada em tempo real, com sua saída servindo como curva indicadora da deposição.

## 7. Conclusão

O presente trabalho teve o objetivo de desenvolver um sistema baseado em redes neurais capaz de monitorar o nível de deposição na Unidade de Destilação U-270 da Refinaria Potiguar Clara Camarão. Os problemas causados pela deposição e incrustação nos equipamentos da Unidade fazem com que o processo precise ser parado frequentemente para manutenção e limpeza dos equipamentos, gerando grandes custos financeiros e operacionais. Assim, existe a necessidade de se realizar estudos de técnicas que permitam reduzir a frequência dessas paradas. Uma das técnicas possíveis é o uso de um sistema de controle inteligente que atue de forma adequada no processo para atenuar os efeitos da deposição, aumentando o intervalo de tempo entre as paradas. A rede neural proposta por esse trabalho poderia ser parte integrante de um sistema de controle para fornecer uma medição do nível da deposição atual no processo.

O trabalho utilizou perceptrons de múltiplas camadas para realizar uma extração de características de algumas das variáveis de processo que são fortemente afetadas pela deposição. Na prática, a rede neural comprime o vetor de entrada para um vetor de uma única dimensão, que pode ser utilizado como curva indicadora da deposição. Foi observado que a curva aumenta de valor logo após a parada para manutenção. Logo, espera-se que essa curva diminua de valor gradativamente com o tempo acompanhando o nível da deposição nos equipamentos da Unidade.

Como perspectivas de melhoras para o trabalho, tem-se o desenvolvimento de um sistema que forme a curva de deposição a partir de um número maior de variáveis de entrada. As correlações entre as variáveis também poderiam ser analisadas para que houvesse uma seleção mais rigorosa daquelas que apresentam mais informação sobre a deposição. Outra possibilidade de melhora é a geração de curvas indicadoras a partir de redes neurais com outras arquiteturas.

## Referências Bibliográficas

FORTUNA, Luigi, GRAZIANI, Salvatore, RIZZO, Alessandro, XIBILIA, Maria G. (2007). *Soft Sensors for Monitoring and Control of Industrial Processes*, Springer.

GONÇALVES, João Carlos (2007). *Estudo de Corrosão em Sistemas de Topo de Unidades de Destilação de Petróleo - Avaliação em Laboratório de Inibidor de Corrosão Comercial e Agentes Neutralizantes*, Dissertação de Mestrado, Universidade Federal do Rio de Janeiro.

HAYKIN, Simon (2000). *Redes Neurais: Princípios e Prática*, Bookman – 2ª Edição.

REBOUÇAS, Diogo Leite (2009). *Sistema de Inferência Neural e Processamento Estatístico Multivariável Aplicado à Indústria do Petróleo*, Monografia de Graduação, Universidade Federal do Rio Grande do Norte.

SONG, Tah Wun (1997). *Condições de processo num trocador de calor*. *Revista de Graduação da Engenharia Química*, São Paulo, v. 1, n. 1, p. 29-42.

SOUZA, Adriana Rosas (1998). *Sistema Neural Auto-Supervisionado Aplicado à Compressão/Reconstrução de Dados/Imagens*, Dissertação de Mestrado, Universidade Federal do Rio Grande do Norte.

ZANATA, Diogo Rafael Prado (2005). *Desenvolvimento de Sensor Virtual Empregando Redes Neurais para Medição da Composição em uma Coluna de Destilação*, Dissertação de Mestrado, Escola Politécnica da Universidade de São Paulo.