UNIVERSIDADE DE SÃO PAULO
ESCOLA DE ENGENHARIA DE SÃO CARLOS
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA
ELÉTRICA DA USP DE SÃO CARLOS

CIRO LUÍS TEIXEIRA CARPINTIERI

UMA APLICAÇÃO DE REDES NEURAIIS NA
INSTRUMENTAÇÃO VIRTUAL DO GRAU ALCOÓLICO
NO PROCESSO INDUSTRIAL DE PRODUÇÃO DO
ETANOL

SÃO CARLOS

2014

CIRO LUÍS TEIXEIRA CARPINTIERI

UMA APLICAÇÃO DE REDES NEURAIIS NA
INSTRUMENTAÇÃO VIRTUAL DO GRAU ALCOÓLICO
NO PROCESSO INDUSTRIAL DE PRODUÇÃO DO
ETANOL

Dissertação de mestrado apresentada à Escola de Engenharia de São Carlos, da Universidade de São Paulo, como parte dos requisitos para a obtenção do Título de Mestre em Ciências, Programa de Engenharia Elétrica.

Área de concentração: Sistemas Dinâmicos

Orientador: Prof. Dr. Rogério Andrade Flauzino

SÃO CARLOS

2014

Trata-se da versão corrigida da dissertação. A versão original se encontra disponível na EESC/USP que aloja o Programa de Pós-Graduação de Engenharia Elétrica.

AUTORIZO A REPRODUÇÃO E DIVULGAÇÃO TOTAL OU PARCIAL DESTES TRABALHOS, POR QUALQUER MEIO CONVENCIONAL OU ELETRÔNICO, PARA FINS DE ESTUDO E PESQUISA, DESDE QUE CITADA A FONTE.

Carpintieri, Ciro Luís Teixeira
C298u Uma aplicação de redes neurais na instrumentação virtual do grau alcoólico no processo industrial de produção do etanol / Ciro Luís Teixeira Carpintieri; orientador Rogério Andrade Flauzino. São Carlos, 2014.

Dissertação (Mestrado) - Programa de Pós-Graduação em Engenharia Elétrica e Área de Concentração em Sistemas Dinâmicos -- Escola de Engenharia de São Carlos da Universidade de São Paulo, 2014.

1. Redes Neurais. 2. Grau alcoólico do etanol. 3. Sensores virtuais. 4. NBR 5992. 5. NBR 15639. 6. Controle de processo. 7. Otimização de processo. I. Título.

FOLHA DE JULGAMENTO

Candidato: Engenheiro **CIRO LUÍS TEIXEIRA CARPINTIERI**.

Título da dissertação: "Uma aplicação de redes neurais na instrumentação virtual do grau alcoólico no processo industrial de produção do etanol".

Data da defesa: 03/04/2014

Comissão Julgadora:

Resultado:

Prof. Dr. **Rogério Andrade Flauzino (Orientador)**
(Escola de Engenharia de São Carlos/EESC)

Aprovado

Prof. Dr. **Aniel Silva de Moraes**
(Universidade Federal de Uberlândia/UFU)

Aprovado

Prof. Dr. **Alessandro Goedtel**
(Universidade Tecnológica Federal do Paraná/UTFPR)

Aprovado

Coordenador do Programa de Pós-Graduação em Engenharia Elétrica e
Presidente da Comissão de Pós-Graduação:
Prof. Titular **Denis Vinicius Coury**

DEDICATÓRIA

Dedico este trabalho aos meus filhos Cauê e Mel, e a minha esposa Denise, minhas fontes de energia e perseverança.

AGRADECIMENTOS

À minha esposa que está sempre ao meu lado e sempre me apoiou, incentivou e ajudou nos momentos difíceis, tornando possível a minha dedicação a este trabalho. Muito obrigado.

À minha mãe que sempre foi exemplo de trabalho, luta e perseverança. Obrigado.

A Smar Equipamentos Industriais e seus diretores, que me incentivaram e permitiram frequentar as aulas e dedicar parte do tempo aos estudos. Obrigado.

Ao Prof. Dr. Rogério Andade Flauzino, pela confiança, apoio e orientação nesta jornada de estudo e pesquisa para a construção deste trabalho. Muito obrigado.

Ao amigo, colega e Prof. Dr. Dennis Brandão, por abrir as portas da USP São Carlos e do seu laboratório me orientando nas matérias que eu deveria cursar. Obrigado.

À Universidade de São Paulo, por disponibilizar os recursos necessários para o desenvolvimento deste trabalho.

Ao Departamento de Engenharia Elétrica e de Computação da Escola de Engenharia de São Carlos – Universidade de São Paulo, que sempre me forneceu o suporte e orientação no dia a dia da vida acadêmica.

Aos colegas e amigos Cleber da Costa Fonseca e Marcio José da Cunha, pelas horas de estudos e apoio durante todo o período do mestrado.

Aos amigos de pós-graduação que sempre me apoiaram e ajudaram nas tarefas e desafios dessa jornada.

Aos amigos e colegas de trabalho que me incentivaram a continuar os estudos.

RESUMO

Carpintieri, C. L. T., (2014). **Uma aplicação de redes neurais na instrumentação virtual do grau alcoólico no processo industrial de produção do álcool etílico.**

Dissertação (Mestrado) – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Paulo, 2014.

A busca por eficiência e qualidade esta presente nas usinas de produção de etanol. A demanda por novas tecnologias e soluções para problemas conhecidos é dinâmica e contínua.

No processo de produção do etanol há a necessidade de se quantificar a qualidade do etanol produzido. Esta análise demanda procedimentos laboratoriais que impõe um tempo entre a coleta da amostra e o resultado das análises laboratoriais. Este tempo afeta a velocidade de reação do sistema de controle de produção a uma variação na qualidade do etanol. Quanto antes se atue na produção, menor é o retrabalho sobre o que foi produzido fora da especificação desejada e maior o rendimento e a produtividade do processo.

Um dos indicadores de rendimento do processo de produção de etanol é a porcentagem de massa de etanol em relação à massa de água contida na solução. Este indicador é representado por “m/m”, e significa grau alcoólico do etanol.

Tabelas alcoométricas são utilizadas para determinar o valor do grau alcoólico, tendo como variáveis de entrada a temperatura e a densidade. O intervalo de temperatura onde as tabelas alcoométricas são válidas não é o mesmo que o processo industrial necessita. O processo industrial trabalha com temperaturas próximas a 90°C. Este fato impõe que as análises do grau alcoólico sejam feitas em laboratório, prejudicando o tempo de resposta ao processo industrial.

Objetivando resolver este problema, este trabalho busca por meio da utilização de redes neurais determinar uma função matemática que possa ser capaz de indicar o valor do grau alcoólico do etanol de maneira precisa e sem que seja necessário o uso de consultas e aproximações por tabelas de referência.

Palavras-chave: Redes Neurais, Grau alcoólico do etanol, Sensores virtuais, NBR 5992 e NBR 15639, Controle de processo, Otimização de processo.

ABSTRACT

Carpintieri, C. L. T., (2014). **An application of neural networks in virtual instrumentation alcohol content in the industrial process of ethanol production.**

(Master Degree) – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Paulo, 2014.

The search for efficiency and quality is present in ethanol plants. The demand for new technologies and solutions to known problems is dynamic and continuous.

In the process of producing ethanol is necessary to quantify the quality of the produced ethanol. This analysis requires laboratory procedures it takes a time between sample collection and results of laboratory analysis. This time affects the reaction speed of the system production control to a variation in the quality of ethanol. The sooner they are acting in the production, lower rework on what was produced outside the desired specification and higher efficiency and productivity of the process.

One of the indicators of process performance ethanol is the percentage mass of ethanol relative to water diluted solution. This indicator is represented by “m/m” and means a degree alcoholic of ethanol.

Alcohol tables are used to determine the amount of degree alcohol having as input variables the temperature and density. The temperature range where the alcohol tables are valid is not the same as the industrial process needs. The industrial process works at temperatures around 90°C. This fact requires the analysis of the degree of alcoholic of the ethanol are made in the laboratory, hampering the response time to the industrial process.

Aiming to solve this fact, this paper aims through the use of neural networks for universal approximation theorem, find a mathematical function that can be implemented in a virtual sensor capable of indicating the value of the alcoholic content of ethanol.

Keywords: Neural Networks, Ethanol Alcoholic degree, Virtual Sensors, NBR 5992 and NBR 15639, Process Control, Optimization process.

LISTA DE FIGURAS

Figura 1. Crescimento da produção de etanol no Brasil.....	2
Figura 2. Processo industrial da cana-de-açúcar.	7
Figura 3. Representação da formula do Álcool Etílico.	9
Figura 4. Processo simplificado de destilação de álcool.	10
Figura 5. Exemplos de densímetros; (a) Modelo de densímetro; (b) Modelo de densímetro de vidro; (c) Modelo de densímetro para etanol Padrão, calibrado a 20°C; (d) Modelo de densímetro usado comercialmente termocompensado.	14
Figura 6. Exemplos de escalas de temperatura.....	20
Figura 7. Cálculo da densidade.....	24
Figura 8. Neurônio biológico.....	29
Figura 9. Neurônio artificial.	30
Figura 10. Algoritmo “ <i>Forward</i> ” e “ <i>Backpropagation</i> ”.	33
Figura 11. Rede Perceptron Multi camada com uma camada escondida.	41
Figura 12. Algoritmos de Aprendizado.	45
Figura 13 Algoritmo de Operação.....	46
Figura 14. Tela de configuração do software AlcoDens.	50
Figura 15. Valor da Densidade – Variação da Temperatura em função do grau INPM.	51
Figura 16. Erro quadrático médio variando em função do Número de neurônios.	53
Figura 17. Grau INPM em função da variação da temperatura, mantendo a densidade constante.	56
Figura 18. Grau INPM em função da densidade com a temperatura fixa.	57
Figura 19. Grau INPM estimado pela rede neural escolhida.....	58
Figura 20. Topologia da rede neural que apresentou melhor desempenho para estimação do grau INPM.	58
Figura 21. Grau INPM em função da temperatura e da concentração em kg/m^3	61
Figura 22. INPM testado extrapolando os valores de temperatura.....	62

LISTA DE TABELAS

Tabela 1. Coeficientes de Bettin (Be).....	15
Tabela 2. Relação entre as escalas de temperatura.....	20
Tabela 3. Um exemplo da tabela gerada pelo programa “Tabelas alcoométricas“.....	48
Tabela 4. Valores do erro máximo cometido pelo AlcoDens.....	49
Tabela 5. Apresentação do resultado da análise dos erros obtidos nas topologias testadas.....	53
Tabela 6. Resultados obtidos nas melhores redes testadas.....	55

LISTA DE SIGLAS

ABNT	Associação Brasileira de Normas Técnicas.
ANP	Agência Nacional do Petróleo.
ATR	Açúcar Total Recuperável.
°GL	Quantidade em mililitros de álcool absoluto contida em 100 ml de mistura hidroalcoólica. Equivale à percentagem em volume.
% v/v	Percentagem em volume.
NBR	Norma Brasileira.
IMETRO	Instituto Nacional de Metrologia, Normalização e Qualidade Industrial.
IPEM	Instituto de Pesos e Medidas.
INPM	Instituto Nacional de Pesos e Medidas.
°INPM	Quantidade em gramas de álcool absoluto contida em 100g de mistura hidroalcoólica. Equivalente à percentagem em massa.
% m/m	Percentagem em massa.
IPEN	Instituto de Pesquisas Energéticas e Nucleares.
PMC	Perceptrom Multi camadas.
PID	Controlador Proporcional Integral Derivativo.
OIML	Organização Internacional de Metrologia Legal.
RNA	Redes Neurais Artificiais.
S.I.	Sistema Internacional de Unidades.
SV	Sensor Virtual.
UNICA	União da Indústria da Cana de Açúcar.
TTB	Tax and Trade Bureau do departamento de comércio do governo americano.

SUMÁRIO

Capítulo 1. Introdução à dissertação de mestrado	1
1.1. Panorama da indústria de etanol no Brasil e contextualização da pesquisa	1
1.2. Motivação	3
1.3. Objetivos	4
1.4. Atividades de divulgação científica desenvolvida.	4
1.4.1. Trabalhos submetidos para congressos científicos	4
1.5. Organização da dissertação	4
Capítulo 2. processo industrial de produção do etanol derivado da cana de açúcar	7
2.1. Etapas do processo produtivo do etanol	7
2.1.1. Corte da cana-de-açúcar	8
2.1.2. Recebimento, pesagem e limpeza	8
2.1.3. Moagem da cana	8
2.1.4. Produção de melaço	9
2.1.5. Fermentação	9
2.1.6. Destilação do mosto fermentado	9
2.2. Aspectos relacionados à medição do grau alcoólico	12
2.3. Norma ABNT NBR 5992 e NBR 15639	13
2.3.1. Massa específica	14
2.3.2. Grau alcoólico em porcentagem em volume	15
2.3.3. Fator de correção do volume: (FCV)	15
2.4. Considerações e trabalhos correlatos	16
Capítulo 3. Técnicas para Medição de Temperatura, Pressão e Densidade em líquidos.....	19
3.1. Medição de temperatura	19
3.1.1. Medição de temperatura por dilatação de líquidos	20
3.1.2. Medição de temperatura por Termopar	21
3.1.3. Medição de temperatura a distância.	21
3.1.4. Medição de temperatura por fibra óptica	22
3.2. Processo de medição de Pressão	22
3.3. Processo de medição de densidade	24

3.3.1. Medição da Densidade	24
3.3.2. Conceito Densidade.....	25
3.3.3. Densidade relativa.....	25
3.3.4. Peso específico	25
Capítulo 4. Fundamentos de redes neurais artificiais	27
4.1. Fundamentos de Redes Neurais Artificiais.....	27
4.2. Neurônio Biológico.	28
4.3. O neurônio artificial.	30
4.3.1. Arquitetura de redes neurais	31
4.4. Rede Perceptron Multicamadas.....	32
4.4.1. Algoritmo “Backpropagation”	32
4.4.2. Regra Delta	34
4.4.3. Temo “Momentum” (δ)	36
4.4.4. Processo de aprendizagem:.....	37
4.4.5. Perceptron Multi camadas como aproximador universal de funções.	38
Capítulo 5. Mapeamento neural do GRAU INPM	43
5.1. Introdução	43
5.2. Descrição dos dados experimentais.....	46
5.3. Avaliação da capacidade de generalização.	48
5.4. Determinação da topologia que melhor representa o mapeamento do grau INPM a partir da densidade e da temperatura.....	52
5.5. Descrição da topologia de rede neural artificial para estimação do Grau INPM...58	
5.6. Dados extrapolados	61
Capítulo 6. Conclusão.....	63
6.1. Conclusões.....	63

CAPÍTULO 1. INTRODUÇÃO À DISSERTAÇÃO DE MESTRADO

1.1. PANORAMA DA INDÚSTRIA DE ETANOL NO BRASIL E CONTEXTUALIZAÇÃO DA PESQUISA

A indústria do etanol no Brasil surgiu com o início da crise do petróleo em 1973. Nesta época o país já possuía uma forte indústria açucareira. Esses dois fatores motivam a possibilidade de se desenvolver um combustível de origem vegetal e onde o país não dependesse tão fortemente do petróleo.

Em 1975 o Brasil criou um programa para desenvolvimento da indústria sucroalcooleira – PróÁlcool. O objetivo deste programa era capacitar a indústria de processamento de cana de açúcar a produzir álcool para ser usado como combustível em automóveis. Até 1979 a crise do petróleo se agravou e o Pró-álcool ganhou muita importância no cenário nacional e internacional, pois o país já tinha conseguido seu objetivo de não mais depender apenas do petróleo para mover seus automóveis. Este sucesso todo gerou divisas e trouxe desafios tecnológicos em muitas áreas de pesquisas relacionada a indústria do álcool, tornando-a uma das maiores forças do agronegócio brasileiro. Ainda, conquistou o reconhecimento internacional em tecnologia de produção de um combustível limpo de fonte renovável, ou seja, um combustível ecológico.

O álcool etílico pertence a uma classe de compostos orgânicos que possui na sua estrutura um ou mais grupos de hidroxilas ("OH") ligados a carbonos saturados. O álcool etílico, $\text{CH}_3\text{CH}_2\text{OH}$, é também conhecido como etanol e trata-se de uma substância orgânica obtida da fermentação de açúcares, hidratação do etileno ou redução a acetaldeído, encontrado em bebidas como cerveja, vinho e aguardente. O álcool etílico é muito utilizado na indústria de perfumaria, como solvente industrial, antisséptico e conservante na medicina.

A Figura 1 apresenta o comparativo da produção do setor sucroalcooleiro nas safras de 2012/2013 e 2013/2014. É possível observar que o etanol está aumentando sua produção em prejuízo da produção de açúcar.

Produtos	Safras		Variação (%)
	2012/2013	2013/2014	
Cana-de-açúcar ¹	531.311,1	594.101,7	↑ 11,82%
Açúcar ¹	34.067,9	34.265,0	↑ 0,58%
Etanol anidro ²	8.844,9	11.015,3	↑ 24,54%
Etanol hidratado ²	12.440,4	14.357,4	↑ 15,41%
Etanol total ²	21.285,3	25.372,7	↑ 19,20%
ATR ¹	72.077,1	79.274,4	↑ 9,99%
ATR/ tonelada de cana ³	135,66	133,44	↓ -1,64%
Mix (%)	açúcar	49,61%	↓
	etanol	50,39%	↑
Litros etanol/ tonelada de cana	40,06	42,71	↑ 6,60%
Kg açúcar/ tonelada de cana	64,12	57,68	↓ -10,05%

Figura 1. Crescimento da produção de etanol no Brasil.

Fonte: UNICA – Estimativa de safra 2013/2014.

A principal utilização do etanol no Brasil é como combustível de motores a explosão. Estes tiveram seu desenvolvimento iniciado no início do programa PróÁlcool. Esta utilização gera um nicho de mercado abrange uma enorme cadeia produtiva autossustentada pela biomassa de origem agrícola.

O ciclo de produção se inicia em fazendas de plantio de cana de açúcar, sob a coordenação de usinas de beneficiamento da cana de açúcar objetivando a produção de etanol e também de açúcar. No entorno desta atividade industrial muitas indústrias se instalam para suprir à demanda de tecnologia e promover o desenvolvimento tecnológico de setores que dão suporte a indústria canavieira. Fazem parte deste grupo a indústria química, a indústria de máquinas e equipamentos industriais, a indústria de caminhões e máquinas agrícolas, a logística de armazenamento, distribuição, transporte e a venda ao consumidor final possuidor de automóveis movidos a etanol.

É nesse contexto que se desenvolve essa pesquisa, ou seja, objetivando fornecer perspectivas de acréscimo tecnológico a setor de produção de álcool. De maneira mais específica, os aspectos motivadores da pesquisa são destacados na Seção 1.2. Os objetivos são tratados na Seção 1.3, as atividades de divulgação científica são apresentadas na Seção 1.4 e a maneira pela qual a dissertação foi organizada é conteúdo da Seção 1.5.

1.2. MOTIVAÇÃO

A busca por eficiência e qualidade está presente, a exemplo de todo o setor industrial, também nas usinas de produção de etanol. A demanda por novas tecnologias e soluções para problemas é dinâmica e contínua.

No processo de produção do etanol há a necessidade de se quantificar a qualidade do etanol produzido. Esta análise demanda procedimentos laboratoriais que impõe um tempo entre a coleta da amostra e o resultado das análises laboratoriais. Este tempo afeta a velocidade de reação do sistema de controle de produção e, conseqüentemente, na variação na qualidade do etanol. Quanto antes se atue na produção menor será o retrabalho sobre o que foi produzido e que esteja fora da especificação desejada. Procedendo assim, maior será o rendimento e a produtividade do processo.

Um dos indicadores de rendimento do processo de produção de etanol é a porcentagem de massa de etanol em relação com à água diluída nesta solução. Este indicador é chamado de grau alcoólico.

O processo industrial de produção de etanol é formado, na maioria das vezes, por três colunas de destilação que precisam trabalhar em sintonia de forma a atingir o valor desejado de grau alcoólico do produto final.

A medição do grau alcoólico é feita de maneira indireta, por meio da medição da temperatura e da densidade da solução etanol e água. Estas duas variáveis são inseridas em uma tabela chamada tabela alcoométrica que indica o valor do grau alcoólico em porcentagem de massa. As Normas Brasileiras que tratam deste procedimento e formalizam a tabela alcoométrica a ser usada em todo território nacional é a NBR 5992 e a NBR 15639.

O ponto de ebulição do etanol é de 78,37 °C o que impõe uma temperatura típica no processo produtivo acima dos valores que as tabelas alcoométricas são válidas. Esta restrição impõe que o etanol seja avaliado em uma temperatura inferior a da saída do processo produtivo o que ocasiona uma demanda de tempo e gasto energético para baixar a temperatura e só então se fazer à medição. Se o etanol estiver com especificação correta, entorno de 93,8 °INPM, o tanque amostrado está aprovado, caso contrário terá que ser feito um trabalho de adequação deste volume de etanol para que apresente a especificação correta, ou seja, o produto terá que voltar para a torre de destilação. Segundo Mayer (2010), em alguns casos

essa concentração é obtida fazendo-se uso de alta taxa de refluxo, o que acarreta elevação no consumo energético. O processo de refluxo consiste em retornar o produto para o processo de destilação para a extração da água na solução. A realização desse processo complementar acarreta em custos os quais são evitadas se o processo estiver ajustado corretamente.

A demanda por um sistema de medição que seja capaz de indicar o valor do grau alcoólico do etanol em tempo real auxiliaria no controle, na estabilidade e na qualidade do etanol. O que este trabalho busca exatamente, é quantificar o grau alcoométrico por meio de uma função matemática, a qual possa ser implementada em um sensor inteligente, obtida com a aplicação de técnicas de redes neurais.

1.3. OBJETIVOS

O objetivo deste trabalho é desenvolver uma rede neural artificial capaz de fornecer o grau alcoólico do etanol dentro da faixa de temperatura e de densidade que opera o processo industrial da produção de etanol de forma a permitir o controle do processo produtivo de forma mais eficiente, reduzindo custos e gastos energéticos, melhorando o desempenho do processo como um todo.

1.4. ATIVIDADES DE DIVULGAÇÃO CIENTÍFICA DESENVOLVIDA.

1.4.1. TRABALHOS SUBMETIDOS PARA CONGRESSOS CIENTÍFICOS

CARPINTIERI, C. L., R. A. FLAUZINO, Uma Abordagem Neural Para o Mapeamento do Grau INPM a Partir de Medidas de Temperatura e Densidade. Artigo submetido ao XX Congresso Brasileiro de Automática, CBA 2014.

1.5. ORGANIZAÇÃO DA DISSERTAÇÃO

Esta dissertação está organizada em seis capítulos. No Capítulo 2 é apresentado o processo industrial de produção do etanol derivado de cana de açúcar. É discutido sobre a moagem, a produção do melaço, a fermentação e destilação. Assim, será possível contemplar o processo industrial até o ponto onde se faz necessário mensurar o grau alcoólico do etanol e como deve ser feita esta medição.

No Capítulo 3 são apresentadas as técnicas para a medição das principais grandezas que estão relacionadas com o grau alcoólico do etanol, ou seja, a temperatura, pressão e densidade em meio líquido.

Os fundamentos referentes à Rede Neural Artificial são tratados no **Erro! Fonte de referência não encontrada..** A metodologia proposta e os resultados alcançados constituem o Capítulo 5. Por fim, no 0 as conclusões são tecidas e trabalhos futuros são propostos.

CAPÍTULO 2. PROCESSO INDUSTRIAL DE PRODUÇÃO DO ETANOL DERIVADO DA CANA DE AÇÚCAR

Nesse capítulo será apresentado, de forma introdutória, os aspectos relacionados ao processo industrial da produção do etanol. O objetivo será de destacar a complexidade envolvida no mesmo além de apontar o local nesse processo produtivo onde a medição do grau alcoólico se faz necessária.

2.1. ETAPAS DO PROCESSO PRODUTIVO DO ETANOL

A cadeia produtiva do etanol pode ser apresentada de maneira esquemática como feito por meio da Figura 2. De forma geral, trata-se de um processo altamente planejado, mecanizado, automatizado e controlado para garantir eficiência e alta produtividade.

Figura 2. Processo industrial da cana-de-açúcar.

Fonte: ROSSELL (2006).

2.1.1. CORTE DA CANA-DE-AÇÚCAR

No estado de São Paulo a cana-de-açúcar começa a ser colhida no mês de Março e a colheita se estende até Dezembro. A colheita é feita em grande parte por máquinas que cortam a cana, retiram o excesso de folhas, picam o caule em pedaços que medem, em média, 30 cm e colocam a cana picada em sextos puxados por um trator que acompanha a colheitadeira. Posteriormente é colocada em caminhões de transporte que seguem para a usina. A mão de obra humana só é usada no corte quando o terreno não permite a entrada das máquinas. A produtividade por hectare de cana é em torno de 85 toneladas. O que qualifica esta matéria prima é o seu teor de sacarose contida no caule da planta.

2.1.2. RECEBIMENTO, PESAGEM E LIMPEZA

Na entrada da usina os caminhões são pesados, uma amostra é analisada inicializando o processo de industrialização. A remuneração ao produtor é baseada no teor de sacarose e produtividade por área plantada. As equipes que trabalharam na colheita são remuneradas pela produtividade na colheita.

Quando a cana chega à usina ela está misturada com restos de palha, gravetos, terra, pedriscos e areia. A palha é separada, peneirada e o que não se consegue retirar é separado pelo processo de lavagem em esteiras contínuas. A água é tratada e recircula no processo várias vezes. Este processo automatizado utiliza apenas 20% da água que se utilizava 30 anos atrás. A palha é encaminhada para ser usada como combustível na caldeira e é queimada para gerar vapor e energia elétrica para suprir de energia toda a usina. O excedente de energia gerada ainda pode ser vendido para as concessionárias de energia elétrica.

2.1.3. MOAGEM DA CANA

Depois de limpa a cana é picada em toletes de comprimento mais ou menos regular para garantir o melhor aproveitamento. A moenda, segundo equipamento na linha de produção é responsável por esmagar a cana e separar o caldo (75%) do bagaço (25%). O bagaço é lavado para garantir que toda a sacarose foi extraída, após isto feito, segue para o secador e depois é encaminhado para ser queimado na caldeira. O caldo, também conhecido como garapa, é constituído de sacarose, água e impurezas. Um banho químico é a próxima etapa, e sua função é uniformizar o líquido e forçar com que as impurezas decantem no fundo do tanque. Estes agentes químicos são reciclados na etapa seguinte e retornam ao processo.

Ao término dessa etapa o caldo está limpo e pronto para seguir para a próxima etapa, a concentração do melaço.

2.1.4. PRODUÇÃO DE MELAÇO

Nesta fase a garapa é aquecida de maneira a aumentar a concentração do açúcar na solução, formando o que se chama de melaço, que consiste numa solução de 40%, aproximadamente, em massa, de sacarose. Neste ponto pode-se obter também o açúcar mascavo, produzido quando parte dessa sacarose se cristaliza e com um processo de purificação se obtém o açúcar cristal e o refinado com um processo industrial mais específico.

2.1.5. FERMENTAÇÃO

O processo de fermentação ocorre quando se acrescenta ao melaço, cepas de enzimas que são o comumente chamado de fermento biológico, como a *Saccharomyces*. O fermento biológico, constituído por leveduras, age quebrando as moléculas de sacarose resultando na liberação do etanol e CO₂. Ainda, tem-se a formação de um resíduo denominado por mosto fermentado. O processo de fermentação garante a produtividade do processo e tem duração de 8 a 15 horas. O mosto contém até 12% de seu volume total de etanol. No passo seguinte o mosto é filtrado em centrífugas e a levedura é separada e reciclada, voltando para o início do processo. A parte líquida é chamado de vinho.

A figura 3 representa a composição química do etanol, formado por dois átomos de carbono, seis átomos de hidrogênio e um de oxigênio.

Figura 3. Representação da formula do Álcool Etílico.

2.1.6. DESTILAÇÃO DO MOSTO FERMENTADO

Na Figura 4 é apresentada uma visão geral do processo tradicional de destilação de álcool, onde a carga do processo, denominada por vinho, é submetida a um processo de destilação para retirada de água, de 80% a 90%, e outros componentes. O produto desta etapa,

denominado por flegma, segue para a fase de retificação, que consiste de uma segunda coluna de destilação, de onde é retirado o álcool hidratado com concentração de 92,6 °INPM.

O resíduo que sobra após a evaporação do etanol é chamado de vinhaça ou vinhoto. Segundo OLIVEIRA e SOUZA (2010) a vinhaça pode ser trabalhada e tratada para ser reaplicada na lavoura como adubo. O uso da vinhaça na lavoura recebe o nome de fertirrigação, pois este subproduto é muito rico em minerais como: potássio, sódio, cálcio e magnésio além de grande carga biológica. A vinhaça Possui ainda 93% de água em sua composição.

Figura 4. Processo simplificado de destilação de álcool.

Segundo SANTOS (2010), para se produzir o álcool anidro, existe uma terceira etapa, a desidratação. Nesta etapa o álcool hidratado é submetido à última etapa de desidratação para alcançar 99,5 °INPM. Existem alguns processos que permitem se conseguir extrair a água do etanol hidratado.

O processo mais tradicional é por meio de uma terceira destilação onde os operadores tem que controlar manualmente a saída de álcool hidratado, monitorando a temperatura das bandejas inferiores da coluna B da Figura 4, identificando se a coluna está carregada ou descarregada de etanol. Se a mesma estiver carregada de etanol, isto contribui para o aumento do teor alcoólico e a temperatura tende a diminuir. Se drenar demais o etanol,

a temperatura tende a aumentar e a concentração do grau alcoólico tende a diminuir, pois começa a aumentar a evaporação da água, o que reduz o valor do grau alcoólico na saída da torre.

Outro processo industrial, mais moderno, é o chamado de ciclo de hexano, que utiliza o hexano como uma terceira substância que, por possuir um ponto de ebulição entre o etanol e o ponto de ebulição da água. Isso permite que o etanol evapore sem a presença de vapores de água restando uma solução de água e hexano. Esta solução passa por um processo industrial para se recuperar o hexano, que volta para o processo novamente. Um pouco de hexano fica misturado com o etanol e este é um ponto negativo desse tipo de processo. O hexano é um produto prejudicial à saúde. Muitas indústrias então preferem não trabalhar com o hexano justamente por causa desta contaminação e escolhem outro processo de desidratação. O hexano é cancerígeno e altamente explosivo.

Um terceiro processo industrial utiliza tecnologia nano molecular para separar o etanol da água. Este processo não utiliza a terceira coluna de destilação e consiste em colocar em um tanque com etanol hidratado, várias esferas feitas de um material especial que possui nano furos. Estes permitem que a molécula de água consiga penetrar na mesma. Por ser maior do que a da água, a molécula do etanol não consegue penetrar nas esferas. Estas esferas são como esponjas que absorvem a água reduzindo a concentração de água e tornando o etanol em condições de ser classificado como etanol anidro.

Estas esferas quando saturadas de água são retiradas do tanque e passam por um processo de aquecimento que retira as moléculas de água do interior das esferas permitindo assim, que elas sejam reutilizadas no processo.

O etanol anidro produzido por este processo é puro e não contem contaminação por um agente químico indesejado. O que limita que este processo industrial seja utilizado em muitas destilarias é o alto custo que a tecnologia exige.

Um quarto processo industrial que está começando a ser usado nas destilarias é o que divide um tanque em duas partes utilizando para isto uma membrana com nano furos. De um lado do tanque é colocado o etanol hidratado e do outro é aplicado uma pressão negativa o que provoca a migração das moléculas de água para o outro lado do tanque. Este processo produz o etanol anidro com menor consumo de energia dentre todos os outros processos. Este

é considerado o processo mais moderno atualmente, mas ainda é um processo caro na ordem de 4 vezes o que se gasta para se produzir com hexano.

Depois de passar pela destilaria o etanol é armazenado em tanques e está pronto para ser distribuído para o consumo, seja ele como etanol hidratado utilizado nos veículos Flex ou anidro utilizado para ser adicionado à gasolina para melhorar a queima e o rendimento nos motores movidos à gasolina.

2.2. ASPECTOS RELACIONADOS À MEDIÇÃO DO GRAU ALCOÓLICO.

A maneira de se quantificar o etanol industrial no momento da venda é em graus o chamado teor alcoólico ou grau alcoólico. Esta indicação é quantificada pela relação entre a massa de uma substância em porcentagem em relação a massa da outra substância contida na solução. No caso do etanol, esta relação é associada à concentração de etanol e água. Esta unidade é também conhecida no Brasil, como grau INPM. No caso do etanol para venda em supermercado em embalagens pequenas (com 96°GL) para consumo doméstico, o valor do etanol é quantificado em GL (Gay-Lussac). Onde o °GL significa a concentração de álcool e água em porcentagem de volume (% v/v), pois, o que se deseja quantificar é o volume e não a massa.

A temperatura que o etanol é submetido no processo industrial é em função do ponto de ebulição do etanol, ou seja, 78°C. Isto implica que na torre de destilação a temperatura varia em torno de 78°C a 82°C, para garantir uma maior pureza do etanol.

Em muitas das usinas do país, a coleta de amostras de etanol nas torres de destilação é controlada manualmente. Os operadores de produção colhem uma amostra do produto e vão até laboratórios, onde, serão usados densímetros e termômetros de imersão. Os valores de temperatura e densidade são lidos e então é feita uma correção do valor da densidade do álcool na temperatura lida para uma densidade na temperatura de 20°C. Essa correção é feita segundo indicado na tabela de correção presente nas normas ABNT NBR 5992 e NBR 15639 obtendo assim, o teor alcoólico do produto em °GL ou °INPM na saída do processo de destilação da usina. Este procedimento serve tanto para álcool hidratado ou álcool anidro.

Somente depois de feita esta medida o operador da planta pode então tomar alguma medida para corrigir o processo industrial, ajustando o teor alcoólico do produto ao valor

desejado. Este controle manual do grau alcoólico independe do processo utilizado para concentrar o teor alcoólico.

É necessário observar que há um atraso, o qual pode ser de horas, entre a coleta da amostra e a análise do teor alcoólico do produto. Este atraso prejudica o controle do processo industrial afetando de maneira significativa os custos de fabricação. Pode-se afirmar dessa forma, que o processo requer dados em tempo real para que as correções necessárias sejam efetivadas e o padrão de qualidade seja atingido mais rapidamente o que reduz custos de retrabalho e gastos com energia.

Portanto, um equipamento que indique o valor do grau alcoólico em tempo real promove um importante ganho, otimizando o processo industrial e reduzindo os custos de produção.

No Brasil há uma diferenciação quanto à nomenclatura adotada. Em ZARPELON (2008) tem-se o seguinte em relação à adoção das nomenclaturas °INPM e °GL:

“Especificamente ao Álcool Anidro Combustível, é mostrado que a especificação americana quanto ao grau alcoólico (99,0 %v/v mínimo) foi baseada nos estudos de equilíbrio com misturas de gasolina, etanol e água, enquanto que a brasileira (99,3°INPM, equivalente a 99,6 %v/v) é muito rígida, encarecendo a produção do álcool. É sugerido, então, o abandono do uso do grau INPM, utilizado somente no Brasil, e a adoção da especificação de 99,3 %v/v para o grau alcoólico do álcool anidro no Brasil.”

2.3. NORMA ABNT NBR 5992 E NBR 15639

A norma ABNT NBR 5992 trata do método do densímetro de vidro para o álcool etílico e suas misturas para a determinação da massa específica e do teor alcoólico. E a ABNT NBR15639 trata do método da densimetria eletrônica para álcool etílico e suas misturas em água na determinação da massa específica e do teor alcoólico.

Ambas as normas fornecem um programa chamado “Tabela alcoométrica” onde é possível obter o valor do grau alcoólico em porcentagem de massa (% m/m), também conhecido no Brasil como °INPM e o grau alcoólico em porcentagem em volume (% v/v) conhecido no Brasil como °GL. Uma semelhança apresentada por estas normas é que elas foram elaboradas para serem trabalhadas em laboratórios, onde o intervalo válido de

temperatura para leitura é de -20 a 40°C. Sendo o valor de 20 °C o valor padrão para a medição da densidade.

Para se determinar a densidade do etanol pela norma ABNT NBR 5992 é necessário à utilização de termômetros de líquido em vidro com indicação de escala em densímetros para medição de etanol, calibrados a 20 °C. Já para a norma ABNT NBR 15639 trabalha a medição da densidade por meio de sistemas eletrônicos, que são densímetros eletrônicos com sistemas automáticos de controle de temperatura. Na Figura 5 são apresentadas ilustrações de vários modelos de densímetros.

Figura 5. Exemplos de densímetros; (a) Modelo de densímetro; (b) Modelo de densímetro de vidro; (c) Modelo de densímetro para etanol Padrão, calibrado a 20°C; (d) Modelo de densímetro usado comercialmente termocompensado.

O medidor de grau GL e grau INPM deve ser usado na saída da coluna do decantador e também em sistemas de medição fiscal, ou seja, onde há a transferência de custódia do produto. As normas ABNT NBR 5992 e NBR 15639 apresentam conceitos os quais são abordados nas subseções seguintes.

2.3.1. MASSA ESPECÍFICA

A massa específica é expressa em quilogramas por metro cúbico. Para o álcool etílico a massa específica, *ME*, pode ser determinada em função do grau alcoólico, *GM*, expresso em porcentagem mássica, e da temperatura de leitura da amostra de álcool etílico, *t*. A aproximação sugerida pelas normas brasileiras é apresentada em (2.1).

$$ME = A_1 + \sum_{k=2}^{12} A_k \left(\frac{GM}{100} - 0,5 \right)^{k-1} - \sum_{k=1}^6 B_k \cdot (t - 20)^k + \sum_{i=1}^n \sum_{k=1}^{m_i} C_{i,k} \left(\frac{GM}{100} - 0,5 \right)^k \cdot (t - 20)^i \quad (2.1)$$

Os coeficientes A, B e C são apresentados por meio da Tabela 1

Onde: n=5; m₁=11; m₂=10; m₃=9; m₄=4; m₅=2;

2.3.2. GRAU ALCOÓLICO EM PORCENTAGEM EM VOLUME

O grau alcoólico indicado em porcentagem em volume é calculado da seguinte forma:

$$GV = GM \cdot \frac{ME_{20^{\circ}C}}{789,23} \quad (2.2)$$

onde GV é o grau alcoólico, expresso em porcentagem em volume; GM é o grau alcoólico em porcentagem em massa, $ME_{20^{\circ}C}$ é a massa específica do álcool a $20^{\circ}C$, expresso em quilogramas por metro cúbico (kg/m^3).

Tabela 1. Coeficientes de Bettin (Be)

k	A_k kg/m^3	B_k $kg/(m^3 \cdot ^{\circ}C^k)$	$C_{1,k}$ $kg/(m^3 \cdot ^{\circ}C)$	$C_{2,k}$ $kg/(m^3 \cdot ^{\circ}C^2)$	$C_{3,k}$ $kg/(m^3 \cdot ^{\circ}C^3)$	$C_{4,k}$ $kg/(m^3 \cdot ^{\circ}C^4)$	$C_{5,k}$ $kg/(m^3 \cdot ^{\circ}C^5)$
1	913,76673	-0,7943755	0,39158709	0,000120832	-3,86832e-05	-5,60249e-07	-1,44417e-08
2	-221,75948	-0,0012168441	1,1518337	0,005746625	0,000209114	-1,26492e-06	1,34705e-08
3	-59,61786	3,60178E-06	-5,4169999	0,12030894	0,002671389	3,4864e06	
4	146,82019	1,77094E-07	13,381608	-0,23519694	0,004104205	-1,51687e-06	
5	-566,5175	-3,41388E-09	4,5899913	-1,0362738	-0,049364385		
6	621,18006	-9,98802E-11	-118,21	2,1804505	-0,017952946		
7	3782,4439		190,5402	4,2763108	0,29012506		
8	-9745,3133		339,81954	-6,8624848	0,023001712		
9	-9573,4653		-900,32344	-6,9384031	-0,54150139		
10	32677,808		-349,32012	7,4460428			
11	8763,7383		1285,9318				
12	-39026,437						

2.3.3. FATOR DE CORREÇÃO DO VOLUME: (FCV)

O fator de correção do volume do álcool em função da temperatura é calculado pela equação:

$$FCV = \frac{ME_{lida}}{ME_{20^{\circ}C}} \cdot (1 + 0,000036 \cdot (t - 20)) \quad (2.3)$$

onde ME_{lida} é a massa específica na temperatura da medida, expressa em quilogramas por metro cúbico; $ME_{20^{\circ}C}$ é a massa específica corrigida a $20^{\circ}C$, expressa em quilogramas por metro cúbico (kg/m^3), 0,000036 é o coeficiente volumétrico de expansão e t é a temperatura da amostra de álcool etílico em graus Celsius.

2.4. CONSIDERAÇÕES E TRABALHOS CORRELATOS

Na literatura correlata a esse tema tem-se um rol de trabalhos científicos os quais objetivam propor alternativas que visem ganhos na eficiência tanto do produto final quanto nas matérias primas e subprodutos gerados nas três fases do processo de destilação.

Em Lucas (2012) foi proposto um estimador dinâmico virtual, baseado em redes neurais, utilizado para inferir a composição de etanol destilado, com base na temperatura, na pressão no interior da coluna, das vazões de refluxo, do vapor no refeedor e da alimentação. Assim, propôs-se um sensor virtual implementado por meio da rede NN-RAX e o mesmo mostrou-se confiável, podendo ser utilizado para estimar o valor da composição do etanol e também para detectar possíveis falhas no processo em análise.

As variáveis empregadas no mapeamento foram adotadas em virtude da dificuldade de medir a variável final do processo. Uma das diferenças entre o desenvolvimento apresentado nesse trabalho e o feito em Lucas (2012) está no fato de se empregar leituras de variáveis físicas da mistura etanol e água, temperatura e densidade, e não variáveis indiretas do processo.

Em Gehlen (2013) tem-se que a operação unitária de destilação exige uma grande quantidade de energia na separação do etanol. É almejado minimizar a energia gasta no processo e nesta tarefa o controle desempenha um papel importante. Um controlador Proporcional-Integral-Derivativo (PID) foi então proposto para assegurar a concentração de etanol combustível no valor desejado, ou seja, próximo de 92° INPM. Baseada na constatação de que os analisadores de concentração apresentam um alto custo e tem um tempo de resposta elevado, desenvolveu-se um modelo de inferência para a concentração. Nesse modelo de inferência a concentração do produto é feita por meio da combinação entre a temperatura do produto e relações termodinâmicas proporcionando o monitoramento e, posteriormente, o controle indireto desta variável. Neste trabalho é ressaltado, a exemplo dos anteriores, que existe a demanda por um analisador concentração que seja eficaz e tenha um tempo de resposta satisfatório ao controle do processo industrial.

De acordo com ALBUQUERQUE (2007), a destilação em usinas de álcool é um processo essencialmente multivariável e com restrições de operação. O comportamento do sistema é extremamente não linear e com elevado grau de acoplamento entre as variáveis, associado a constantes de tempo elevadas, gerando atrasos na resposta, o que resulta em

transientes elevados quando o processo é perturbado ou é feito algum ajuste para corrigir o processo.

Em MORAIS (2011) é apresentado um procedimento para o desenvolvimento de um analisador virtual, utilizando técnicas neuro fuzzy para a predição da composição de topo de uma coluna destilação metanol e água em uma planta piloto. O analisador virtual é um modelo matemático que pode ser empregado para estimar variáveis de interesse a partir de variáveis secundárias de fácil medição. Esta tecnologia surge de uma real dificuldade operacional ou do alto custo de obtenção da variável desejada.

Em OLIVEIRA e SOUZA (2010) é apresentado um estudo onde foi desenvolvido um equipamento, sensor virtual, para monitoramento *on line* do teor de potássio na vinhaça *in natura* visando quantificar e dosar a quantidade de vinhaça a ser lançada por hectare de área plantada. A vinhaça é um subproduto no processo de industrialização do álcool. Neste trabalho também foi utilizada técnicas de redes neurais para identificar o valor calculado desejado da concentração de potássio.

Em WERLE (2009) é descrito que as colunas de destilação necessitam de sistemas de controle apropriados para se obter a especificação desejada do produto e uma operação estável no processo. A medição confiável e precisa da composição, de alguma propriedade ou dos produtos, é uma das principais dificuldades em torres de destilação. Para a determinação destas, normalmente são empregadas análises de laboratório ou analisadores de processo. Contudo, existem problemas decorrentes desses métodos, quando aplicados no controle em malha fechada. Entre esses problemas estão: demora entre a coleta da amostra e a disponibilização do resultado da análise; e pouca confiabilidade dos analisadores de processo. Para tentar suprir esta dificuldade lançam-se mão de modelos inferenciais. A inferência é basicamente uma correlação de uma propriedade em função de variáveis escolhidas, que são continuamente medidas no processo de produção. O resultado da inferência é usado diretamente pelo controlador, ocasionando a atuação rápida sobre uma ou mais válvulas de controle, ou para manipular o *set point* de uma temperatura controlada de forma a corrigir uma propriedade fora da especificação.

Esta técnica foi utilizada neste estudo, por meio do desenvolvimento de analisadores virtuais, ou sensores por software empregando rede neural artificial na sua arquitetura, mostrando o quão alinhado está o trabalho com as pesquisas internacionais.

No presente trabalho, o objetivo é desenvolver uma rede neural artificial para se ter um mapeamento do grau INPM a partir da temperatura e da densidade e que esteja de acordo com as tabelas alcoométricas ditadas pelas normas ABNT NBR 5992 e NBR 15639.

A contribuição deste desenvolvimento consiste em produzir um resultado mais rápido e confiável do teor alcoólico do álcool hidratado na saída da coluna de retificação (coluna B e C), para auxiliar o sistema de controle a atuar de maneira mais efetiva tomando decisões mais acertadas para manter o teor alcoólico mais próximo dos valores de desejados dos processos.

CAPÍTULO 3. TÉCNICAS PARA MEDIÇÃO DE TEMPERATURA, PRESSÃO E DENSIDADE EM LÍQUIDOS

Neste capítulo são apresentadas as grandezas físicas necessárias envolvidas na estimação do INPM, ou seja, a temperatura, que com sua variação provoca a alteração no volume pela dilatação dos líquidos, a pressão, que permite o controle da massa a ser medida. A combinação destas duas grandezas permite a continuidade da medição por meio da densidade. A densidade é a grandeza que conduz aos valores estudados e trabalhados nesta dissertação. Muitas das informações contidas neste capítulo foram obtidas no livro de BEGA e DELMÉE (2006) e OMEGA (1989).

3.1. MEDIÇÃO DE TEMPERATURA

A temperatura é quantificada por meio de escalas termométrica as quais buscam expressar a o quão quente ou frio um corpo está. Para a construção de uma escala é preciso dois pontos de referência. Os pontos tomados como referência são a temperatura de degelo da água e a temperatura de ebulição da água. Observando que foi usada a água como referência e as medições feitas ao nível do mar, ou melhor, a uma atmosfera. A diferença de temperatura entre estes dois pontos foi escalonada para poder indicar valores intermediários entre os dois pontos de referencia.

As escalas habitualmente empregadas para se medir a temperatura são as escalas Celsius, Kelvin, Fahrenheit e Rankine. A Figura 6 apresenta um comparativo entre essas escalas. A Tabela 2 mostra como se relacionam os valores da temperatura em diferentes unidades.

A temperatura é medida por comparação em um equipamento chamado termômetro. Este é o nome dado ao equipamento que possui um tubo de vidro selado com um bulbo em uma das extremidades. Dentro deste bulbo há mercúrio ou álcool. O vidro não se expande ou contrai tanto quanto o líquido que esta dentro do bulbo com a variação temperatura. A mudança na temperatura faz com que, o líquido se dilate e suba ou desça dentro do tubo. Este

tubo tem marcações de graus com a escala de temperatura desejada, ou seja, é calibrado segundo uma escala.

Figura 6. Exemplos de escalas de temperatura.

A necessidade de se medir a grandeza temperatura, fez surgir não só as escalas, mas também contribuiu para o surgimento de técnicas e métodos de se detectar esta diferença de energia. A técnica apresentada acima é conhecida como “Termômetro de Bulbo”. Outras técnicas são destacadas nas subseções seguintes.

Tabela 2. Relação entre as escalas de temperatura.

Escala	Fahrenheit	Celsius	Kelvin	Rankine
F	F	$(F - 32)/1,8$	$(F-32) * 5/9 + 273,15$	$F + 459,67$
°C	$(C * 1,8) + 32$	C	$C + 273,15$	$(C * 1,8) + 273,15$
K	$(K-273,15)*9/5+32$	$K - 273,15$	K	$(K-273,15) / 1.8 + 491,67$
R	$°R-459,67$	$(R - 491,67)/1.8$	$(R-491,67)/1,8 + 273,15$	R

3.1.1. MEDIÇÃO DE TEMPERATURA POR DILATAÇÃO DE LÍQUIDOS

Os termômetros de dilatação de líquidos baseiam-se na lei de expansão volumétrica de um líquido com a temperatura dentro de um recipiente fechado. Este recipiente pode ser de vidro transparente ou metálico.

O termômetro é constituído por um reservatório, cujo tamanho depende da sensibilidade desejada, soldada a um tubo capilar de seção, mais uniforme possível e fechado na parte superior. O reservatório e parte do capilar são preenchidos de um líquido, que pode

ser Mercúrio (-38 °C a 550 °C), Tolueno (-80 °C a 100 °C), Álcool ou Acetona (-100 °C a 70 °C). A parede do tubo capilar é graduada em graus ou frações deste. A medição de temperatura se faz pela leitura da escala no ponto em que se tem o topo da coluna líquida.

3.1.2. MEDIÇÃO DE TEMPERATURA POR TERMOPAR

Um termopar consiste de dois condutores metálicos, de natureza distinta, na forma de metais puros ou de ligas homogêneas. Os fios são soldados em um extremo ao qual se dá o nome de junta quente ou junta de medição. A outra extremidade dos fios é levada ao instrumento de medição da força eletromotriz (f.e.m), fechando um circuito elétrico por onde flui a corrente.

O ponto onde os fios que formam o termopar se conectam ao instrumento de medição é chamado de junta fria ou de referência.

O aquecimento da junção de dois metais gera o aparecimento de uma diferença de potencial. Este princípio conhecido por efeito *Seebeck* propiciou a utilização de termopares para a medição de temperatura. A diferença de potencial que surge pelo gradiente de temperatura existente entre as juntas quente e fria, é aquisitado por um sistema de leitura, amplificado, relacionado a uma escala de temperatura. Então é indicado, registrado ou transmitido por sinais elétricos ou por protocolos industriais de comunicação.

Os termopares são muito utilizados no ambiente industrial. Na indústria sucroalcooleira estes sensores são empregados, na maioria das vezes, em virtude de sua robustez e facilidade de uso.

3.1.3. MEDIÇÃO DE TEMPERATURA A DISTÂNCIA.

A medição de temperatura a distância é feita pelos termômetros infravermelhos, termovisores ou pirômetros. Seu princípio de funcionamento baseia-se na leitura da radiação infravermelha emitida pelos materiais, permitindo medições precisas a distâncias seguras evitando-se riscos e desligamentos desnecessários.

Toda forma de matéria com temperatura acima do zero absoluto emite radiação infravermelha de acordo com a temperatura. Denomina-se essa propriedade de radiação característica e é resultado do movimento das moléculas.

A intensidade deste movimento depende da temperatura do objeto. Como o movimento das moléculas representa deslocamento de cargas, radiação eletromagnética é emitida. Estes fótons movem-se com a velocidade da luz e comportam-se de acordo com os princípios óticos conhecidos. Eles podem ser defletidos, focados por lentes, ou refletidos por superfícies reflexivas. O espectro desta radiação tem faixa de 0,7 a 1000 μm de comprimento de onda. Por esta razão, a radiação não pode ser vista a olho nu.

3.1.4. MEDIÇÃO DE TEMPERATURA POR FIBRA ÓPTICA

A fibra óptica foi inventada em 1952 pelo físico indiano Narinder Singh Kanpany. Este dispositivo é formado basicamente por um tubo de vidro o qual é composto por dois tipos distintos de vidro e assim tem-se a formação de um fio cilíndrico concêntrico. Estes tipos de vidros possuem índices de refração diferentes e esta diferença de densidade permite que um feixe de luz fique aprisionado dentro do material mais interno do fio. Quando se varia a temperatura de um material a sua densidade sofre influências da temperatura e isto resulta em uma alteração na forma e na velocidade como que a luz se propaga na fibra. Estas alterações são infinitesimais, mas passíveis de serem medidas. Este conhecimento resultou na criação de sensores de temperatura baseados na tecnologia conhecida com Redes de Bragg.

Os sensores que usam fibras óticas como elemento sensor são compactos e apresentam sensibilidades comparáveis aos similares convencionais. Existem muitos sensores comerciais feitos com fibras óticas, para medição de temperatura e também para a medição de pressão, rotação, sinais acústicos, corrente, fluxo, etc.

3.2. PROCESSO DE MEDIÇÃO DE PRESSÃO

A grandeza física que representa a força por unidade aplicada a uma área é chamada de pressão. As unidades mais comuns são: PSI, (lb./in²) Pa, N/m², kgf/cm², mmHg, mmH₂O, lbf/plg², Atm, e bar.

$$P = \frac{F}{A} \quad (3.1)$$

Assim, pode-se definir a pressão como a razão entre a força e a área. No caso de líquidos pode-se representar a pressão como sendo a relação entre peso específico e a altura da coluna deste líquido, no recipiente como expresso em (3.3)

$$P = \frac{dF}{dA} \quad (3.2)$$

$$P = \rho \cdot g \cdot \Delta h \quad (3.3)$$

Onde:

P = pressão medida;

ρ = densidade específica do fluido;

g = valor da gravidade no local da medição;

Δh = diferença de altura entre dois pontos;

Observando (3.3) é possível extrair o valor da densidade de um fluído utilizando a pressão, a aceleração da gravidade e coluna deste fluído. Portanto um sensor de pressão pode ser utilizado para fornecer a densidade de um fluído. Esta é então uma opção de medição para ser utilizada para medir a densidade de um fluído, pois já existem transmissores inteligentes de pressão que já são microprocessados e poderiam ser utilizados para receber a implementação de um medidor de densidade.

Pelo teorema de Stevin, que define o teorema dos vasos comunicantes, a diferença de pressão entre dois pontos de um fluído em repouso é igual ao produto do peso específico do fluído pela diferença da cota entre estes dois pontos, ou seja:

$$\rho = \frac{P}{g \cdot (h_2 - h_1)} \quad (3.4)$$

A Figura 7 apresenta esquematicamente os termos de (3.3) para o cálculo da densidade.

Figura 7. Cálculo da densidade.

Existem vários tipos de sensores de pressão. Os mais conhecidos são os sensores com tecnologia capacitiva, mas há sensores com tecnologia piezo resistivos, indutivos e célula de silício ressonante. Os sensores de pressão são compostos por duas partes:

- ❖ Conversão de pressão em força ou deslocamento.
- ❖ Conversão de força ou deslocamento em sinal elétrico.

O sensor transforma a pressão aplicada sobre ele em um sinal elétrico que é condicionado de forma a ampliar, digitalizar e quantificar o sinal elétrico em um valor que represente o valor da pressão. O valor coletado é então transmitido ao elemento de controle da planta. Os tipos de mediação de pressão podem ser:

- ❖ *Gauge pressure* - diferença entre a pressão de interesse e a pressão ambiente.
- ❖ Pressão diferencial - diferença de pressão entre dois pontos distintos no circuito. Este sinal de pressão pode ser transformado em sinal de densidade.
- ❖ Pressão absoluta - medida por um sensor de pressão diferencial com um dos lados em 0 psi. (aproximadamente vácuo).

3.3. PROCESSO DE MEDIÇÃO DE DENSIDADE

3.3.1. MEDIÇÃO DA DENSIDADE

Por meio do método da pressão diferencial, conhecendo a diferença de pressão entre dois pontos separados por uma distância fixa e conhecida é possível de se determinar a densidade de líquidos.

A pressão diferencial é medida por um sensor capacitivo, onde dois diafragmas ficam submersos e separados por uma distância conhecida. Por meio de capilares a pressão em cada

um dos diafragmas é transferida para a célula capacitiva. O valor da capacitância é proporcional à diferença de pressão sentida pelos diafragmas e assim é possível determinar a densidade do líquido. Este método permite obter uma precisão de $0,0001 \text{ g/cm}^3$.

Outro meio de se medir a densidade é pelo princípio da lei da oscilação harmônica – Um tubo em formato de “U”, quando excitado por um campo eletromagnético, passa a oscilar em sua frequência natural. O período de oscilação é função da densidade do líquido no tubo. Assim, quando se mede o período de oscilação se obtém a densidade do líquido com precisão na ordem de $0,0002 \text{ g/cm}^3$.

3.3.2. CONCEITO DENSIDADE

A densidade, ρ , é o quociente entre a quantidade de massa m e o volume v que essa quantidade ocupa.

$$\rho = \frac{m}{v} \quad (3.5)$$

3.3.3. DENSIDADE RELATIVA

A densidade relativa, ρ_r , é a densidade de uma substância medida em relação à densidade da água a 20°C .

$$\rho_r = \frac{\rho}{\rho_{\text{Água}}} \quad (3.6)$$

3.3.4. PESO ESPECÍFICO

Define-se peso específico como a razão entre o peso da substância em módulo e o seu volume. Portanto, o peso específico é o produto entre a densidade e a aceleração da gravidade (g).

$$\text{Peso}_{\text{específico}} = \frac{mg}{V} \quad (3.7)$$

$$\rho_e = \rho \cdot g \quad (3.8)$$

O volume de um líquido é proporcional à variação da temperatura e de um coeficiente de dilatação próprio do líquido em estudo.

Um exemplo do efeito da variação de volume dos líquidos provocada pela variação da temperatura é o de uma carreta com a capacidade para 30.000 litros carregada na base a 25°C e chegando ao posto com uma temperatura de 30 °C tem-se que o produto chegará com 150 litros acima do volume registrado no carregamento.

Uma implicação deste fenômeno é a utilização de uma unidade de medida que utiliza a massa e não o volume como indicador. O INPM (%m/m) é a medida da concentração alcoólica que indica a relação entre a massa do etanol e a massa da água em porcentagem contida na mistura etanol e água.

CAPÍTULO 4. FUNDAMENTOS DE REDES NEURAIS ARTIFICIAIS

4.1. FUNDAMENTOS DE REDES NEURAIS ARTIFICIAIS

Segundo SILVA, SPATTI e FLAUZINO (2010) “Redes neurais artificiais são modelos computacionais inspirados no sistema nervoso de seres vivos. Possuem a capacidade de aquisição e manutenção do conhecimento (Baseado em informações) e podem ser definidas como um conjunto de unidades de processamento, caracterizadas por neurônios artificiais, que são interligados por um grande número de interconexões (sinapses artificiais), sendo as mesmas representadas por vetores e matrizes de pesos sinápticos.”

Segundo Geromel (2003), as RNAs são técnica computacionais que têm capacidade para solucionar problemas por intermédio de circuitos simples que simulam o funcionamento e o comportamento do cérebro humano. Elas apresentam um modelo inspirado na estrutura neural de organismos inteligentes, que adquirem conhecimento através da experiência, ou seja, aprendendo, errando e fazendo descobertas. Uma rede neural artificial pode ter centenas ou até milhares de unidades de processamento, enquanto o cérebro de um mamífero pode conter muitos bilhão de neurônios.

Uma rede neural é caracterizada pela capacidade de aprender por meio de exemplos, pela capacidade de se adaptar ou aprender, pela capacidade de generalização, pela capacidade de agrupar e organizar informações e ainda são tolerantes a falhas. Uma rede neural pode ser utilizada em várias áreas de conhecimento, como:

- ❖ **Reconhecimento de padrões:** Vários padrões são apresentados à rede, após o aprendizado destes padrões a rede será capaz de dada uma entrada classificar esta entrada à um dos padrões apresentados. Exemplos: reconhecimento de faces, impressões digitais, escrita e assinaturas, objetos e imagens. Como exemplo a identificação de imagens médicas e faces em visão computacional, etc.

-
- ❖ **Categorização agrupamento e *clustering*.** A rede explora semelhanças entre as amostras e agrupa aquelas que reconhecem como parecidas criando classes. Exemplos, classificação de cores, formas geométricas, dimensões, aromas. Estes são utilizados para avaliar imagens captadas por satélite ou câmeras industriais para selecionar pacotes, separar perfiz de credito para clientes de uma instituição financeira etc.
 - ❖ **Aproximações de funções matemáticas.** A rede é capaz de gerar uma função Y com o comportamento de uma função X conhecida. A exigência neste caso é que todos os valores apresentados a rede estejam dentro dos domínios da função X . Obs.: Esta é a área de conhecimento em que este trabalho se desenvolve.
 - ❖ **Previsão e predição, dado um conjunto de medidas** $\{ Y(t_1), Y(t_2), Y(t_3) \dots Y(t_n) \}$ a rede neural é capaz de prever o valor da medida $Y(t_{n+1})$. Exemplo: valores futuros para se construir uma curva de tendência. Um exemplo desta característica é a previsão de comportamento de ações no mercado financeiro.
 - ❖ **Otimização de sistemas.** A rede é capaz de minimizar ou maximizar uma função objetiva sujeita ou não a um conjunto de restrições. Exemplos: propagação linear (PL), propagação não linear (PNL), propagação inteira (PI), propagação binária (PB), propagação dinâmica (PD). Um exemplo mais prático relacionado ao dia a dia é o controle do tráfego de trens, otimizando a velocidade e tempo parado em estações.

4.2. NEURÔNIO BIOLÓGICO.

O neurônio é a principal célula que compõe o cérebro humano. Mostrada na figura (8). Segundo Haykin (2000), o cérebro humano é considerado o mais fascinante processador baseado em carbono existente. É composto por aproximadamente 10 bilhões de neurônios. Todas as funções e movimentos do organismo estão relacionados ao funcionamento dessas pequenas células. Os neurônios estão conectados uns aos outros através de sinapses e, juntos, formam uma grande rede, chamada rede neural. As sinapses transmitem estímulos através de diferentes concentrações de Na^+ e K^+ , e o resultado pode ser estendido por todo o corpo

humano. Esta grande rede proporciona uma fabulosa capacidade de processamento e armazenamento de informação.

Figura 8. Neurônio biológico.

Fonte: INSTITUTO FRANCISCO PACHECO DIAS (2010).

Temos as seguintes definições:

- ❖ Dendritos – tem por função receber os estímulos transmitidos pelos outros neurônios.
- ❖ Corpo Celular ou Soma – é o corpo do neurônio, é responsável por coletar e combinar as informações vindas de outros neurônios.
- ❖ Axônio – é constituído de uma fibra tubular que pode alcançar até alguns metros, é responsável por transmitir os estímulos para outras células.

O sistema nervoso é formado por um conjunto extremamente complexo de neurônios, cuja comunicação é realizada através de impulsos. Quando um impulso é recebido, o neurônio o processa e, passado um limite de ação, dispara um segundo impulso que produz uma substância neurotransmissora a qual flui do corpo celular para o axônio (que por sua vez pode ou não estar conectado a um dendrito de outra célula). O neurônio que transmite o pulso pode controlar a frequência de pulsos aumentando ou diminuindo a polaridade na membrana pós-sináptica. Eles têm um papel essencial na determinação do funcionamento, comportamento e raciocínio do ser humano. Ao contrário das redes neurais artificiais, as naturais não transmitem sinais negativos; sua ativação é medida pela frequência com que emitem pulsos, frequência esta de pulsos contínuos e positivos. As redes naturais não são uniformes como as artificiais e apresentam uniformidade apenas em alguns pontos do organismo. Seus pulsos não são síncronos ou assíncronos, devido ao fato de não serem

contínuos, o que as difere de redes artificiais (LABORATOTY OF COMPUTATIONAL INTELLIGENCE – LABIC, 2010).

Assim, o sistema nervoso humano pode ser visto como um sistema com três estágios: o centro do sistema (cérebro), representado pela rede neural que recebe informações e toma decisões; os receptores, que convertem os estímulos do corpo ou do ambiente em impulsos elétricos que transmitem informação para a rede neural; e os atuadores, que, por sua vez, convertem impulsos elétricos em respostas para a saída do sistema (LABORATOTY OF COMPUTATIONAL INTELLIGENCE – LABIC, 2010).

4.3. O NEURÔNIO ARTIFICIAL.

O neurônio artificial é um modelo matemático que representa um neurônio biológico. Segundo McCulloch (1943) o neurônio artificial é representado segundo a figura (9).

Figura 9. Neurônio artificial.

Onde: $X_1, X_2, \dots, X_n$ são os sinais de entrada do neurônio, $W_1, W_2, \dots, W_n$ são os pesos sinápticos do neurônio, Θ é chamado de limiar de ativação do neurônio, Σ é a representação de um combinador linear com uma função de ativação, M é a saída do combinador linear, $g(\mu)$ é a função de ativação (limitada a saída) do neurônio, Y é o sinal de saída do neurônio.

Então, obtemos a representação matemática do neurônio artificial representadas pelas equações (4.1) e (4.2).

$$\mu = \sum_{i=1}^n W_i.X_i - \Theta \quad (4.1)$$

$$Y = g(\mu) \quad (4.2)$$

Em termos matemáticos as funções de ativação mais típicas são as seguintes:

❖ Função Degrau:

$$g(\mu) = \begin{cases} 1, se \mu \geq 0; \\ 0, se \mu < 0; \end{cases} \quad (4.3)$$

❖ Função Sinal:

$$g(\mu) = \begin{cases} 1, se \mu \geq 0; \\ -1, se \mu < 0; \end{cases} \quad (4.4)$$

❖ Função Linear:

$$g(\mu) = \mu; \quad (4.5)$$

❖ Função Logística:

$$g(\mu) = \frac{1}{1 + e^{-\beta\mu}} \quad (4.6)$$

❖ Função Tangente Hiperbólica:

$$g(\mu) = \frac{1 - e^{-\beta\mu}}{1 + e^{-\beta\mu}} \quad (4.7)$$

4.3.1. ARQUITETURA DE REDES NEURAIAS

A arquitetura de uma rede neural define como os neurônios estão arranjados e esta fortemente relacionada ao mecanismo utilizado para o treinamento. Existem várias arquiteturas neurais, como a rede *feedforward* de UNICA camada ou de múltiplas camadas, redes recorrentes, onde há uma realimentação entre os neurônios de camadas diferentes.

4.4. REDE PERCEPTRON MULTICAMADAS

As redes Perceptron Multicamadas (PMC) é uma arquitetura constituída por uma camada de entrada, pelo menos uma camada escondida e por uma camada neural de saída. Podemos ver na figura (12), a camada de entrada (CE) onde X são as amostras, as camadas escondidas (CN1) e (CN2), onde W_1 e W_2 são as matrizes de peso e a camada de saída (CNS) onde W_3 é a matriz de peso desta camada e Y_1 é o sinal de saída.

4.4.1. ALGORITMO “*BACKPROPAGATION*”

O processo de treinamento das redes (PMC) é realizado utilizando o algoritmo “*Backpropagation*”, que consiste na aplicação sucessiva de duas fases específicas:

Passo “*Forward*” ou “Propagação”: As amostras são aplicadas nas entradas da rede e as informações são propagadas, camada a camada até suas saídas. Onde é obtida a resposta da rede. (No início não se altera a matriz de pesos). O objetivo desta fase é obter as saídas pela propagação dos sinais de entrada, passando camada por camada.

Passo “*Backpropagation*” A partir das saídas calcula-se o erro que será propagado de volta para as camadas anteriores, objetivando-se o ajuste das matrizes de pesos. Este algoritmo é também chamado de “Regra Delta”.

Com os pesos ajustados é executado novamente o passo “*Forward*” e produzida nova saída e novamente é executado o passo “*Backpropagation*”. Este ciclo continua até que as saídas obtidas não produzam mais alterações nas matrizes de peso no passo “*Backpropagation*”.

A representação física da rede (PMC) é apresentada na figura (12) e o seu desenvolvimento matemático é explicado na sequência.

Figura 10. Algoritmo “Forward” e “Backpropagation”.

Onde:

CE é a camada de entrada;

X₁, X₂...X_n São as entradas;

Y₁, Y₂...Y_n São as saídas;

CN1 e CN2 são as camadas neurais 1 e 2;

CNS é a camada neural de saída;

W_{1ij} é o peso sináptico. Efetua a conexão entre o “j-ésimo” neurônio da camada “I” ao “i-ésimo” neurônio da camada “I-1”;

I_{1j} é a entrada ponderada do “j-ésimo” neurônio da camada “I”;

$$I_{1j} = \sum_{i=0}^N w_{1ji} \times X_{ij} \quad (4.8)$$

I_{2j} é a entrada ponderada do “j-ésimo” neurônio 2.

$$I_{2j} = \sum_{i=0}^{N1} w_{2ji} \times Y_{1ij} \quad (4.9)$$

I_{3j} é a entrada ponderada do “j-ésimo” neurônio 3.

$$I_{3j} = \sum_{i=0}^{N2} w_{3ji} \times Y_{2ij} \quad (4.10)$$

Y_{ij} é a saída do “i-ésimo” neurônio da camada “I”

$$Y_{1j} = g(I_{1i}) \Rightarrow \in R^{N1} \quad (4.11)$$

Saída do “i-ésimo” neurônio da camada 2.

$$Y_{2j} = g(I_{2i}) \Rightarrow \in R^{N2} \quad (4.12)$$

Saída do “i-ésimo” neurônio da camada 3.

$$Y_{3j} = g(I_{3i}) \Rightarrow \in R^{N3} \quad (4.13)$$

4.4.2. REGRA DELTA

Esta regra é utilizada no ajuste dos pesos da RNA, usando o erro quadrático entre a saída Y e a saída desejada d , ou seja, determina-se W* tal que o erro quadrático (E), sobre todo o conjunto de amostras seja o mínimo possível.

As funções (sinais) de erro são definidas como:

Erro Quadrático relativo à “k-ésima” camada.

$$E(k) = \frac{1}{2} \sum_{j=1}^{N3} (d_j(k) - Y_{3j}(k))^2 \quad (4.14)$$

Erro Quadrático Médio relativo a todas as “P” amostras.

$$E_M = \frac{1}{P} \sum_{k=1}^P E(k) \quad (4.15)$$

Este conceito é usado como critério de parada quando o erro (E) atinge o valor mínimo definido no algoritmo de aprendizagem.

O algoritmo “*Backpropagation*” pode ser dividido em duas partes, uma destinada ao ajuste dos pesos da camada de saída e outra destinada ao ajuste dos pesos das camadas intermediárias.

Empregando a definição de gradiente e explorando a regra da diferenciação em cadeia, temos:

$$\nabla E^{(3)} = \frac{\partial E}{\partial W_{ji}^{(3)}} = \frac{\partial E}{\partial Y_j^{(3)}} \cdot \frac{\partial Y_j^{(3)}}{\partial I_j^{(3)}} \cdot \frac{\partial I_j^{(3)}}{\partial W_{ji}^{(3)}} \quad (4.16)$$

Temos que $g'(\cdot)$ é a derivada de primeira ordem da função de ativação considerada, obtemos:

$$\frac{\partial E}{\partial W_{ji}^{(3)}} = -(d_j - Y_j^{(3)}) \cdot g'(I_j^{(3)}) \cdot Y_j^{(2)} \quad (4.17)$$

Assim o ajuste da matriz de pesos $W_{ij}^{(3)}$ deve ser efetuado em direção oposta do gradiente a fim de minimizar o erro, ou seja:

$$\Delta W_{ij}^{(3)} = -\eta \cdot \frac{\partial E}{\partial W_{ji}^{(3)}} \Leftrightarrow \Delta W_{ji}^{(3)} = \eta \delta_{ji}^{(3)} \cdot Y_i^{(2)} \quad (4.18)$$

Onde $\delta_{ji}^{(3)}$ é definido como o gradiente local em relação ao j -ésimo neurônio da camada de saída, sendo o mesmo dado por:

$$\delta_j^{(3)} = (d_j - Y_j^{(3)}) \cdot g'(I_j^{(3)}) \quad (4.19)$$

De forma complementar a expressão (4.18) pode ser também convertida no seguinte procedimento iterativo:

$$W_{ij}^{(3)}(t+1) = W_{ij}^{(3)}(t) + \eta \cdot \delta_{ji}^{(3)} \cdot Y_i^{(2)} \quad (4.20)$$

Onde η é a taxa de aprendizagem do algoritmo *backpropagation*. Em notação algorítmica, esta expressão é equivalente à seguinte:

$$W_{ij}^{(3)} \leftarrow W_{ij}^{(3)} + \eta \cdot \delta_{ji}^{(3)} \cdot Y_i^{(2)} \quad (4.21)$$

Portanto, a expressão (4.21) ajusta os pesos dos neurônios da camada de saída da rede levando-se em consideração a diferença observada entre as respostas produzidas por suas saídas em relação aos seus valores desejados.

Diferentemente dos neurônios pertencentes a camada de saída do PMC, para os neurônios das camadas intermediárias não se tem acesso de forma direta os valores desejados para suas saídas. Nesta situação, os ajustes de seus pesos sinápticos são efetuados por intermédio de estimativas dos erros de saída produzidos por aqueles neurônios da camada imediatamente posterior, os quais foram previamente ajustados.

$$W_{ij}^{(2)} \leftarrow W_{ij}^{(2)} + \eta \cdot \delta_j^{(2)} \cdot Y_i^{(1)} \quad (4.22)$$

A expressão (4.22) ajusta os pesos dos neurônios da segunda camada escondida, levando-se em consideração a retropropagação do erro advinda a partir dos neurônios da camada de saída.

A matriz de pesos da primeira camada intermediária é calculada de maneira análoga a da segunda camada intermediária, mas neste caso o sinal de saída da camada anterior é substituído pelos valores da camada de entrada e a estimativa do erro vem da retropropagação da segunda camada intermediária.

$$W_{ij}^{(1)} \leftarrow W_{ij}^{(1)} + \eta \cdot \delta_j^{(1)} \cdot X_i \quad (4.23)$$

A expressão (4.23) ajusta os pesos dos neurônios da primeira camada neural intermediária, levando-se em consideração a retropropagação do erro advinda a partir dos neurônios da segunda camada intermediária.

Os algoritmos de retropropagação foram apresentados e podem ser generalizados para quaisquer topologia de uma rede PMC, independente da quantidade de camadas intermediárias.

4.4.3. TEMO “MOMENTUM” (δ)

Diversas variações do método *backpropagation* foram propostas com o objetivo de tornar o processo de convergência mais eficiente. O método de inserção do termo *momentum* é uma variação simples de ser efetuada no algoritmo *backpropagation* e incrementa a velocidade de convergência do algoritmo. A inserção deste parâmetro visa ponderar o quão as matrizes de sinápticas foram alteradas entre duas interações anteriores e sucessivas

A expressão (4.24) representa a velocidade de aproximação do algoritmo *backpropagation* com o termo *momentum* para a L-ésima camada.

$$\Delta W_{ji}^{(L)}(t+1) = W_{ji}^{(L)}(t) + \alpha * (W_{ji}^{(L)}(t) - W_{ji}^{(L)}(t-1)) + \eta * \delta_j^{(L)} * \gamma_i^{(L-1)} \quad (4.24)$$

A expressão (4.25) é o termo Momentum. A taxa de *momentum* (α) é um valor compreendido entre [0,1]. Se assumir o valor “0” anula o efeito do *momentum*, mas se assumir valores maiores que ”0” o termo *momentum* passa a ser relevante atuando positivamente no processo de convergência. Para uma variação elevada na correção da matriz

de peso entre duas interações o termo *momentum* contribuirá de maneira efetiva para a convergência, mas quando esta variação for pequena a contribuição do termo *momentum* também será pequena e os ajustes dos pesos das matrizes serão conduzidos apenas pelo termo de aprendizagem, como ocorre no *backpropagation convencional*.

$$\alpha * (W_{ji}^{(L)}(t) - W_{ji}^{(L)}(t-1)) \quad (4.25)$$

A expressão (4.26) é o termo de aprendizagem do *backpropagation*.

$$\eta * \delta_j^{(L)} * \gamma_i^{(L-1)} \quad (4.26)$$

O uso do termo *momentum* implica acelerar a convergência da rede à razão de $\eta/(1-\alpha)$, conforme análises efetuadas em Reed & Marks II (1999). Os valores compreendidos entre $(0.05 \leq \mu \leq 0,75)$ e $(0 \leq \alpha \leq 0,9)$ são normalmente recomendados para treinamento de redes PMC (Rumelhart *et alii*, 1986).

4.4.4. PROCESSO DE APRENDIZAGEM:

A propriedade mais importante das redes neurais é a habilidade de aprender como problema proposto e com isso melhorar seu desempenho. Isso é feito através de um processo iterativo de ajustes aplicado a seus pesos, o treinamento. O aprendizado ocorre quando a rede neural atinge uma solução generalizada para uma classe de problemas.

Denomina-se algoritmo de aprendizado a um conjunto de regras bem definidas para a solução de um problema de aprendizado. Cada modelo de rede neural possui um algoritmo de aprendizado específico. Estes algoritmos diferem entre si principalmente pelo modo como os pesos são modificados.

O objetivo do processo de aprendizagem é ajustar os parâmetros livres, que são a matriz de pesos e o limiar de ativação para cada neurônio. O resultado do processo de aprendizagem é a matriz de peso capaz de gerar a saída desejada ao problema apresentado.

Segundo SILVA, SPATTI e FLAUZINO (2010), o treinamento supervisionado é um caso típico de inferência indutiva pura, em que os parâmetros livres são ajustados em função de se conhecer *a priori* quais são as saídas desejadas ao sistema investigado.

Considerado uma amostra do treinamento, o valor da diferença (erro) entre o potencial de ativação $\{u\}$ produzido pela rede e o respectivo valor desejado $\{d\}$ é usado para ajustar os pesos $\{W_0, W_1, W_2, \dots, W_n\}$ da rede.

O processo treinamento resulta em minimizar o erro quadrático médio (E_M) garantindo o melhor ajuste da rede para produzir a resposta mais acertada.

O termo “Época de treinamento” ou simplesmente “Época” é usado para indicar o número de vezes que todo o conjunto de dados de entrada é apresentado a RNA com o objetivo de ajustar seus pesos. Em outras palavras é o número de vezes que o algoritmo de aprendizado foi executado até obter um resultado é satisfatório e o erro é menor que o erro máximo estipulado.

Os tipos de treinamentos existentes são dois. O treinamento Supervisionado, onde para cada dado de entrada é apresentado um resultado esperado, permitindo que os pesos sejam ajustados para minimizando o erro. O processo de treinamento Não Supervisionado não apresenta um resultado esperado e o processo de treinamento é auto organizado, generalizando em subconjuntos com características similares.

4.4.5. PERCEPTRON MULTI CAMADAS COMO APROXIMADOR UNIVERSAL DE FUNÇÕES.

Um rede PMC treinada com o algoritmo *backpropagation* é capaz de implementar qualquer mapeamento não linear que relacione entradas e saídas. Postulado de CYBENKO (1989).

Teorema da aproximação universal: Dado que $g(\cdot)$ é limitada, monótona crescente e contínua arbitraria f pode ser implementada por um PMC com apenas uma camada escondida com neurônios, ou seja,

$$F(x_1, x_2, x_3, \dots, x_N) = \sum \alpha_i * g\left(\sum_{j=1}^N w_{ij} * x_j - \Theta_i\right) \quad (4.19)$$

O erro de aproximação é dado por:

$$|F(x_1, x_2, x_3, \dots, x_n) - f(x_1, x_2, x_3, \dots, x_n)| \leq \varepsilon \quad (4.20)$$

Uma rede PMC apresenta uma grande capacidade de resolver problemas do tipo Aproximação de Funções. Esta aplicação consiste em mapear o comportamento de um processo baseado em diversas medições efetivas de suas entradas e a saídas, ou seja, o sistema é treinado segundo um estado de entradas, a estabelecer uma correlação e responder conforme a saída desejada. Esta é uma das principais características intrínsecas das redes neurais artificiais. O aprendizado a partir de exemplos.

Os sistemas do tipo “caixa preta” pode-se beneficiar desta capacidade das redes PMC de estabelecer relações, pois apresentam apenas dados conhecidos de entrada e saída. As redes PMC realmente têm sido muito empregadas para este tipo de modelamento de sistemas, onde os métodos convencionais se tornam muito complexos, acabam produzindo resultados insatisfatórios.

O teorema da aproximação universal aplicado ao PMC, é baseado nas demonstrações de Kolmogorov (1957) fornece as bases necessárias para mapear funções algébricas [Cybenko,1989].

Uma função de ativação $g(.)$ a ser adotada nas redes PMC, assume ser contínua e limitada em suas imagens, como são as funções logística e a tangente hiperbólica, demonstra-se que a uma topologia de PMC, constituída apenas de uma camada escondida, é capaz de mapear qualquer função contínua no espaço das funções reais.

$$Y(X_1, X_2, \dots, X_n) = \sum_{i=1}^{n_1} \lambda_i \cdot g_i^{(1)}(u_i^{(1)}) \quad (4.21)$$

Camada escondida da PMC.

$$u_i^{(1)} = \sum_{j=1}^n w_{ij}^{(1)} \cdot x_j - \theta_j \quad (4.22)$$

onde λ_i são constantes que ponderam as funções $g_i^{(1)}(.)$.

As equações expressões (equações 4.21 e 4.22) podem ser traduzidas para uma representação de rede PMC, composta de fato por apenas uma camada neural escondida, tendo a função logística (equação 4.6) como ativação para os respectivos neurônios desta camada. A função tangente hiperbólica (equação 4.7) também é válida como função de ativação.

Usando a função linear (equação 4.5) como função de ativação da camada de saída, temos apenas um neurônio nesta camada realizando uma combinação linear das funções de ativação logística implementada pelos neurônios da camada anterior, camada escondida.

Segundo SILVA, SPATTI e FLAUZINO (2010. p. 136), um PMC com apenas uma camada escondida é suficiente e capaz de mapear qualquer função não linear contínua definida em um domínio compacto (fechado). Há a possibilidade de se utilizar mais de uma camada escondida para incrementar o desempenho do processo de treinamento e reduzir sua estrutura topológica. Deve-se observar que o teorema da aproximação universal enuncia tão somente uma camada escondida, entretanto o número de neurônios para realizar tal tarefa é desconhecido e dependerá da complexidade do problema tratado.

Segundo SILVA, SPATTI e FLAUZINO (2010. p. 137), devemos observar o fato de se uma função apresentar uma descontinuidade (inversão da função) no domínio da função implica no uso de pelo menos duas camadas escondidas ao PMC. No caso do problema proposto não há a necessidade de se utilizar mais de uma camada escondida.

A capacidade de generalização de uma RNA com PMC precisa testada, pois é a generalização que vai garantir a eficiência e eficácia da RNA. Para isto é utilizada a técnica da validação cruzada ou *Cross Validation Method*, que consiste em executar três passos simples.

1. Formar dois subconjuntos com o total de dados de entrada disponível. Um conjunto chamado de “Conjunto de treinamento” com uma quantidade de dados variando de 80 a 90% do total de dados disponíveis. O outro conjunto, chamado de “Conjunto de teste” com os outros dados restantes, (10 a 20%). Os conjuntos de dados devem ser escolhidos aleatoriamente.
2. O mesmo “Conjunto de treinamento” deve ser usado para treinar todas as topologias candidatas.
3. O subconjunto de teste é usado, após o treinamento, para validar o melhor modelo testado. Sendo este o que generaliza melhor.

O termo *Overfitting* é usado quando a RNA tem um desempenho satisfatório durante o treinamento, mas insatisfatório durante a fase de validação.

Figura 11. Rede Perceptron Multi camada com uma camada escondida.

CAPÍTULO 5. MAPEAMENTO NEURAL DO GRAU INPM

5.1. INTRODUÇÃO

O objetivo do trabalho é desenvolver uma rede neural artificial que mapeie o grau alcoólico do etanol em função da temperatura e da densidade. A faixa de temperatura que será considerada é de 10 a 100 °C. Esta faixa de temperatura abrange toda a faixa de processo industrial de destilação do álcool. Assim, tem-se a possibilidade de se construir um sensor inteligente capaz de operar *on line* no processo, reduzindo custos de operação, aumentando a repetibilidade do processo, reduzindo o tempo para tomada de decisão e efetuando os ajustes e correções necessárias para assegurar a qualidade e repetibilidade do processo industrial.

Este objetivo possui dois desafios. O primeiro é gerar e validar uma curva utilizando técnicas e algoritmos de redes neurais, capaz de representar com o mínimo erro possível a curva fornecida pelas tabelas alcoométricas definida como padrão pelas normas ABNT NBR 5992 e ABNT NBR 15639. É importante ressaltar que esta curva é válida apenas para o intervalo de temperatura de -20 a 40 °C. Este fato obriga o processo industrial a despende energia e tempo para reduzir o valor da temperatura do etanol na saída do processo de uma faixa entre 75 e 90°C para um valor abaixo de 40 °C e só então fazer tomar a medida do teor alcoólico do produto em análise.

A conquista deste resultado representa um ganho na velocidade de processamento da informação entre o método convencional e o proposto com as técnicas de rede neural. Ainda, a complexidade e o número elevado de operações matemáticas resultam no aumento da imprecisão dos cálculos efetuados pelo processador. O resultado apresentado pelo algoritmo neural produz uma quantidade muito reduzida de cálculos, se comparada à função convencional.

O processo de aprendizado e treinamento da rede neural despende um volume muito superior de cálculos e tempo de processamento, mas estes cálculos ocorrem apenas no processo da geração das matrizes de pesos e em um computador diferente do adotado no

processo industrial. A curva utilizada no processo industrial é apenas a curva gerada pelas matrizes de pesos sinápticos.

O segundo objetivo deste trabalho é gerar uma curva representativa confiável para valores de grau alcoólico em temperaturas superiores a 40 °C. A geração de valores superiores entre o intervalo de 40°C até 100°C será feito pelo software chamado AlcoDens. O segundo objetivo, então é gerar uma curva pelo processo de redes neurais, capaz de calcular de maneira efetiva, eficaz com um mínimo de termos e operações matemáticas, suficiente para viabilizar a implementação de um equipamento capaz de ler os valores de grau INPM para temperaturas de até 100 °C.

O algoritmo apresentado na Figura 12 representa o processo de aprendizado ou de treinamento da RNA usado neste trabalho. O algoritmo consiste em definir os valores de entrada oferecidos à RNA. A entrada deve ser normalizada para a faixa de [0,1], no caso do uso da função sigmoide, e para a função de ativação tangente hiperbólica o escalonamento deve ser feito para o intervalo de [-1,1]. O procedimento de normalização é indicado por contribui para incrementar o desempenho do treinamento.

O algoritmo de aplicação é apresentado na Figura 13. Este algoritmo é chamado de algoritmo de operação, pois, nenhum tipo de ajuste de pesos é feito nesta fase, apenas a implementação das matrizes de pesos já encontradas no processo anterior deve ser processada com os valores de entrada sendo capaz de produzir o resultado final desejado. Esta afirmação é válida se os dados apresentados à rede treinada estão inseridos dentro do domínio da função de treinamento.

Figura 12. Algoritmos de Aprendizado.

Figura 13 Algoritmo de Operação.

5.2. DESCRIÇÃO DOS DADOS EXPERIMENTAIS.

Os dados para este trabalho foram obtidos simulando valores por meio de programas que geram valores de grau alcoólicos baseados na temperatura e densidade da mistura de etanol e água. Estes programas estão apresentados a seguir.

O primeiro deles é o programa chamado “Tabelas Alcoométricas” desenvolvido por uma associação de três entidades, ABNT – Associação Brasileira de Normas Técnicas, UNICA - União da indústria de Cana-De-Açúcar, e Gaiec Gestão Agroindustrial. É fornecido junto com as Normas ABNT NBR 5992 e ABNT NBR 15639.

A função deste programa é a de gerar tabelas que relacionam os valores de temperatura em °C, a densidade ou massa específica lida em kg/m^3 , Massa Específica a 20 °C em kg/m^3 , Grau Alcoólico em % m/m (INPM), Grau Alcoólico a 20 °C em % v/v (GL) e o fator de correção do volume.

O usuário entrar com o intervalo de variação do grau alcoólico fornecendo os valores do grau alcoólico inicial, do grau alcoólico final e o incremento desejado do grau alcoólico em % m/m para cada calculo. É necessário fornecer também o intervalo da temperatura que se deseja calcular o grau alcoólico, ou seja, o valor da temperatura inicial e o valor da temperatura final, bem como no caso do grau alcoólico, o incremento da temperatura em °C a ser calculado em cada iteração. Depois de preparada a interface do programa iniciam-se os cálculos e a tabela é gerada no formato do programa Excel.

Observando que o objetivo final desta dissertação é trabalhar com valores de temperatura variando entre 10 °C e 100°C. A tabela alcoométrica fornecida pela norma ABNT NBR 5992 é válida apenas para os valores calculados para a faixa de temperaturas entre 10 °C a 40 °C. Para se trabalhar com valores de temperaturas acima de 40 °C é necessário fazer uso do segundo programa chamado AlcoDens (versão 2.3 de Setembro de 2013) que fornece a tabela alcoométrica válida até 100 °C, na opção Density-Strength Converter. Este programa é desenvolvido e comercializado pela Katmar Software por meio do site <http://www.katmarsoftware.com/alcodens.htm>.

A tabela 3 foi gerada pelo programa “Tabelas alcoométricas” é apresentada quando se fornece os seguintes valores de entrada: Trata-se apenas de um exemplo resultado do programa.

- ❖ Grau Alcoólico Inicial igual a “0”,
- ❖ Grau Alcoólico Final igual a “5”,
- ❖ O incremento do Grau Alcoólico em % m/m igual a 1,
- ❖ Temperatura Inicial igual a “0”,
- ❖ Temperatura Final igual a “20”,
- ❖ O incremento de temperatura em °C igual a “5”,

Tabela 3. Um exemplo da tabela gerada pelo programa “Tabelas alcoométricas”.

Temperatura °C	Massa específica lida kg/m³	Massa específica a 20 °C kg/m³	Grau alcoólico % m/m	Grau alcoólico a 20 °C % v/v	Fator correção volume
0,0	999,84	998,20	0,00	0,00	1,0009
0,0	997,94	996,31	1,00	1,26	1,0009
0,0	996,14	994,48	2,00	2,52	1,0009
0,0	994,43	992,73	3,00	3,77	1,0010
0,0	992,81	991,02	4,00	5,02	1,0011
0,0	991,27	989,38	5,00	6,27	1,0012
5,0	999,96	998,20	0,00	0,00	1,0012
5,0	998,06	996,31	1,00	1,26	1,0012
5,0	996,25	994,48	2,00	2,52	1,0012
5,0	994,52	992,73	3,00	3,77	1,0013
5,0	992,88	991,02	4,00	5,02	1,0013
5,0	991,31	989,38	5,00	6,27	1,0014
10,0	999,70	998,20	0,00	0,00	1,0011
10,0	997,79	996,31	1,00	1,26	1,0011
10,0	995,98	994,48	2,00	2,52	1,0011
10,0	994,24	992,73	3,00	3,77	1,0012
10,0	992,58	991,02	4,00	5,02	1,0012
10,0	990,98	989,38	5,00	6,27	1,0013
15,0	999,10	998,20	0,00	0,00	1,0007
15,0	997,20	996,31	1,00	1,26	1,0007
15,0	995,38	994,48	2,00	2,52	1,0007
15,0	993,63	992,73	3,00	3,77	1,0007
15,0	991,95	991,02	4,00	5,02	1,0008
15,0	990,33	989,38	5,00	6,27	1,0008
20,0	998,20	998,20	0,00	0,00	1,0000
20,0	996,31	996,31	1,00	1,26	1,0000
20,0	994,48	994,48	2,00	2,52	1,0000
20,0	992,73	992,73	3,00	3,77	1,0000
20,0	991,02	991,02	4,00	5,02	1,0000
20,0	989,38	989,38	5,00	6,27	1,0000

5.3. AVALIAÇÃO DA CAPACIDADE DE GENERALIZAÇÃO.

Os dados empregados no treinamento das redes neurais artificiais foram gerados por meio do software AlcoDens que possui uma amplitude de validade da equação de -20 a 100 °C. Sendo que os valores de -20 a 40 °C seguem o padrão internacional como a norma brasileira e os valores de 40 °C a 100°C foram obtidos em medições feitas em laboratório e tabeladas com o máximo rigor segundo o fabricante do software.

Segundo o site da Organização Internacional de Metrologia Legal (OIML), o Brasil participa do “Sistema de Certificado OIML” com reconhecimento internacional. Este sistema possibilita que qualquer fabricante de um instrumento de medição, associado à metrologia legal, possa solicitar um certificado OIML a um país membro que faça parte do sistema. No Brasil esta responsabilidade é do INMETRO. Isto significa que as normas ABNT NBR 5992 e NBR 15639 seguem o padrão internacional.

Segundo o manual do AlcooDens, na faixa de temperatura de -20 °C a 40 °C, os dados apresentados pelo AlcoDens são compatíveis com as OIML Alcoholometric Tabelas Internacionais. Isto significa que os dados têm variações ligeiras nas Tabelas americanas. Os dados OIML são mais recentes, e provavelmente mais precisos do que as tabelas TTB (Tax and Trade Bureau) do governo americano. Os cálculos foram testados com AlcoDens nas tabelas TTB e não foram encontradas diferenças significativas.

Na gama de 40 °C a 100 °C existem muito menos dados publicados, e mais escassas concordâncias entre fontes. Nesta faixa de temperatura será mais indicado utilizar os dados para os cálculos do processo, em vez da mistura, e a precisão é mais do que suficiente para fazer cálculos de concepção do processo.

Os dados acima de 40 °C foram testados com dados tabulados à nossa disposição e os erros típicos máximos destacados na Tabela 4 foram encontrados ao se calcular as densidades de concentrações conhecidas. Na Figura 14 é apresentada a interface do programa AlcoDens.

Tabela 4. Valores do erro máximo cometido pelo AlcoDens.

Faixa de temperatura	faixa de medição	Erro	Erro Médio
(Celsius)	(% m/m)	(kg/m ³)	(kg/m ³)
40- 100	0 - 100	0,38	0,09

Figura 14. Tela de configuração do software AlcoDens.

Primeiramente foi validada a tabela alcoométrica definida pela ABNT para garantir que a aplicação dos dados gerados pelo AlcoDens. As grandezas envolvidas, Temperatura e % em massa de etanol, tiveram seus intervalos de validação entre 0 a 40 °C e de 0 a 100 graus INPM. Foram geradas tabelas com pontos em temperatura variando de 2 em 2 graus, sendo representado pela nomenclatura: $t \{0 \ 40 : 2\}$ e $\%m/m \{0 \ 100 : 2\}$. O processo de validação apresentou resultado altamente satisfatório possibilitando a adoção dos valores do AlcoDens para o treinamento das redes neurais artificiais.

Foi gerado por meio do programa AlcoDens, uma tabela relacionando a temperatura com a %m/m do etanol obtendo a densidade da solução. Na aplicação em questão o fluxo de informação é diferente, ou seja, no campo se tem disponível a temperatura e a densidade da solução e a informação desejada é o grau INPM (%m/m) do Etanol em processo. A Figura 15

apresenta a variação da temperatura de 10 °C a 100 °C em função da variação do grau INPM de 0 a 100. Desta função resulta a densidade em kg/m^3 .

Figura 15. Valor da Densidade – Variação da Temperatura em função do grau INPM.

Observando a distribuição das cores apresenta na Figura 15, pode-se notar o comportamento físico da solução. O Etanol é menos denso que a água e isto implica que, quanto mais concentrada de etanol a solução, menos água ela possui e consequentemente menor sua massa específica.

5.4. DETERMINAÇÃO DA TOPOLOGIA QUE MELHOR REPRESENTA O MAPEAMENTO DO GRAU INPM A PARTIR DA DENSIDADE E DA TEMPERATURA

Para este trabalho, a característica que as redes neurais artificiais possuem de compactar a base de dados e assim, concentrar as informações, é explorada proporcionando uma contribuição de grande valor. Conseguir concentrar as informações necessárias em um sistema capaz de fornecer um resultado satisfatório dado um sinal de entrada de concentração e temperatura, é uma grande contribuição ao processo industrial, pois resulta em requisitos de hardware com menor volume de memória disponível.

Para se definir a melhor topologia partiu-se de uma arquitetura formada por apenas uma camada neural escondida. Para a definição do número de neurônios necessários capazes de sintetizar a informação, foi testada a topologia variando o número de neurônios na camada escondida.

Um conjunto de dados foi gerado com valores de temperatura variando de 10 °C a 100 °C a um passo de 2 graus e os dados de INPM variando de 0 a 100 com um intervalo também de 2 graus.

O conjunto de dados utilizados foi dividido em dois conjuntos. Um dedicado ao treinamento das redes neurais candidatas, formado por 20% do total dos dados e outro conjunto para a validação e escolha da melhor topologia, formado pelos 80% restantes.

Foram geradas topologias utilizando 2 neurônios na camada escondida até 15 neurônios nesta camada. Aumentando um neurônio por teste. O teste consistiu em apresentar os dados (temperatura, densidade), a uma mesma topologia 30 vezes, variando apenas a matriz de pesos sinápticos inicial em cada teste, ou seja, este conjunto de dados foi apresentado para testes 420 vezes.

A Figura 16 apresenta como o erro quadrático médio para cada uma das topologias testadas considerando-se o conjunto de treinamento. Pode-se observar que a partir de uma rede com 12 neurônios o erro quadrático médio começou a oscilar em torno de 0,6 a 0,7 indicando que topologias com número de neurônios superior a este já havia atingido o máximo de generalização possível.

Figura 16. Erro quadrático médio variando em função do Número de neurônios.

Das 420 RNA's treinadas inicialmente selecionou-se os 10%, 42 RNA's ao todo, que melhor generalizaram os dados. Esse conjunto de 42 RNA's tivera seu treinamento continuado com 100% dos dados disponíveis e por um número de 1000 épocas. O sumário dos resultados alcançado após o treinamento intensivo dessas 42 RNA's está apresentado na Tabela 5 e na Tabela 6 têm-se as 10 melhores RNA's.

Tabela 5. Apresentação do resultado da análise dos erros obtidos nas topologias testadas.

Índice da RNA	Número de neurônios	Número de pesos sinápticos	Erro absoluto médio	Desvio padrão do erro	Percentil de 5% do erro	Percentil de 95% do erro	Base do intervalo de confiança
1	13	53	0,0119	0,0159	-0,0240	0,0259	0,0499
2	13	53	0,0160	0,0214	-0,0294	0,0325	0,0619
3	15	61	0,0165	0,0236	-0,0369	0,0358	0,0727
4	14	57	0,0113	0,0150	-0,0249	0,0238	0,0487
5	12	49	0,0205	0,0292	-0,0404	0,0438	0,0842
6	15	61	0,0145	0,0205	-0,0295	0,0323	0,0617
7	13	53	0,0210	0,0285	-0,0459	0,0437	0,0896
8	14	57	0,0103	0,0136	-0,0205	0,0214	0,0420
9	12	49	0,0137	0,0203	-0,0326	0,0352	0,0678
10	14	57	0,0131	0,0194	-0,0288	0,0297	0,0586
11	15	61	0,0114	0,0157	-0,0265	0,0245	0,0509
12	12	49	0,0160	0,0239	-0,0344	0,0367	0,0712

Índice da RNA	Número de neurônios	Número de pesos sinápticos	Erro absoluto médio	Desvio padrão do erro	Percentil de 5% do erro	Percentil de 95% do erro	Base do intervalo de confiança
13	14	57	0,0105	0,0142	-0,0215	0,0246	0,0462
14	14	57	0,0169	0,0231	-0,0339	0,0359	0,0697
15	15	61	0,0136	0,0204	-0,0300	0,0318	0,0618
16	10	41	0,0222	0,0311	-0,0474	0,0420	0,0894
17	12	49	0,0198	0,0275	-0,0416	0,0429	0,0844
18	12	49	0,0207	0,0277	-0,0410	0,0405	0,0814
19	14	57	0,0179	0,0256	-0,0349	0,0409	0,0758
20	15	61	0,0084	0,0114	-0,0168	0,0186	0,0354
21	8	33	0,0218	0,0301	-0,0495	0,0522	0,1017
22	14	57	0,0181	0,0260	-0,0392	0,0359	0,0751
23	14	57	0,0106	0,0148	-0,0239	0,0240	0,0479
24	15	61	0,0102	0,0141	-0,0222	0,0218	0,0441
25	12	49	0,0226	0,0313	-0,0545	0,0502	0,1047
26	14	57	0,0132	0,0187	-0,0283	0,0309	0,0593
27	13	53	0,0146	0,0205	-0,0320	0,0335	0,0655
28	15	61	0,0238	0,0350	-0,0502	0,0527	0,1029
29	11	45	0,0264	0,0379	-0,0511	0,0530	0,1040
30	13	53	0,0162	0,0226	-0,0350	0,0344	0,0694
31	6	25	0,0532	0,0740	-0,1105	0,1064	0,2169
32	12	49	0,0146	0,0209	-0,0287	0,0344	0,0631
33	14	57	0,0137	0,0193	-0,0302	0,0273	0,0574
34	7	29	0,0469	0,0689	-0,1105	0,0965	0,2070
35	13	53	0,0119	0,0174	-0,0271	0,0302	0,0573
36	13	53	0,0123	0,0174	-0,0279	0,0278	0,0556
37	8	33	0,0218	0,0301	-0,0495	0,0522	0,1017
38	14	57	0,0115	0,0152	-0,0230	0,0256	0,0486
39	8	33	0,0469	0,0663	-0,0930	0,0976	0,1906
40	9	37	0,0653	0,0955	-0,1315	0,1321	0,2635
41	14	57	0,0231	0,0319	-0,0418	0,0528	0,0946
42	12	49	0,0232	0,0307	-0,0530	0,0475	0,1004

Tabela 6. Resultados obtidos nas melhores redes testadas.

Índice da RNA	Número de neurônios	Número de pesos sinápticos	Erro absoluto médio	Desvio padrão do erro	Base do intervalo de confiança
20	15	61	0,0084	0,0114	0,0354
24	15	61	0,0102	0,0141	0,0441
8	14	57	0,0103	0,0136	0,0420
13	14	57	0,0105	0,0142	0,0462
23	14	57	0,0106	0,0148	0,0479
4	14	57	0,0113	0,0150	0,0487
11	15	61	0,0114	0,0157	0,0509
38	14	57	0,0115	0,0152	0,0486
1	13	53	0,0119	0,0159	0,0499

A Figura 17 apresenta o comportamento do grau INPM em função da temperatura para diferentes valores de densidade. Por outro lado, na Figura 18 tem-se o comportamento do grau INPM em função da densidade para diferentes valores de temperatura. Os valores apresentados em ambas às figuras são referentes à RNA com melhor desempenho, ou seja, a de índice 20 conforme se pode observar por meio da Tabela 6. A escolha desta rede foi devido ao fato dela apresentar o menor erro absoluto médio, o menor desvio padrão e melhor base do intervalo de confiança. Esta rede produz o resultado de saída com melhor exatidão e precisão dentre todas redes as treinadas.

A rede 1, apresentou apenas 13 neurônios, o que significa que a rede possui apenas 53 pesos sinápticos, sendo a rede com menor consumo de recursos de memória e um menor processamento matemático devido ao fato de exigir um menor número de operações matemáticas para produzir a saída desejada. Esta rede poderia ser usada, se estes parâmetros fossem decisivos, e hardware utilizado não possuísse os recursos necessários para se utilizar a rede de número 20. Como este trabalho busca também a rede com a melhor exatidão, a rede escolhida preferencialmente foi a rede número 20.

Na Figura 19 tem-se um mapa com isolinhas de como o grau INPM se comporta em função da temperatura e da densidade. Pode-se observar que para valores de temperatura abaixo de 80 °C o grau INPM se comporta de maneira praticamente linear, mas conforme a temperatura aumenta, fatores físicos passam a atuar de maneira mais significativa adicionando mais não linearidade ao processo.

Por exemplo, em 1 Atm o etanol muda seu estado de líquido para gasoso e para se manter o etanol em estado líquido e a temperaturas superiores a 78°C é preciso elevar a pressão a que a solução esta exposta. Esta elevação de pressão impõe uma maior não linearidade ao processo. Pelos resultados alcançados a RNA escolhida mapeou coerentemente tais não linearidades.

Figura 17. Grau INPM em função da variação da temperatura, mantendo a densidade constante.

Figura 18. Grau INPM em função da densidade com a temperatura fixa.

Figura 19. Grau INPM estimado pela rede neural escolhida.

5.5. DESCRIÇÃO DA TOPOLOGIA DE REDE NEURAL ARTIFICIAL PARA ESTIMAÇÃO DO GRAU INPM

A topologia da rede rede neural artificial que apresentou o melhor desempenho na estimação do grau INPM é destacada por meio da Figura 20.

Figura 20. Topologia da rede neural que apresentou melhor desempenho para estimação do grau INPM.

Pode-se observar por meio da Figura 20 que a rede neural que melhor desempenho apresentou na estimação do grau INPM a partir de medições de temperatura e densidade

possui uma camada oculta com 15 neurônios com função de ativação do tipo tangente sigmóide. Na camada de saída tem-se um único neurônio com função de ativação linear.

Conectando a camada de entrada à camada oculta tem-se os pesos sinápticos da matriz $\mathbf{W}_1$. O bias de cada um dos neurônios da camada oculta é representado por meio do vetor $\mathbf{b}_1$. A conexão entre os neurônios da camada oculta com o neurônio da camada de saída ocorre na forma como ponderam os pesos sinápticos contidos no vetor $\mathbf{W}_2$ e o bias do neurônio da camada de saída é dado por $\mathbf{b}_2$. Essas matrizes e vetores definem em termos paramétricos a rede deural artificial que desempenha o mapeamento do grau INPM a partir da temperatura e da densidade. Numéricamente tem-se a seguinte composição para as matrizes, vetores e escalares que definem a referida rede neural artificial:

$$\mathbf{W}_1 = \begin{pmatrix} 0.4013 & 3.5138 \\ -0.6252 & -5.6431 \\ -0.8159 & -5.5130 \\ -0.4018 & 9.7879 \\ -0.6814 & -1.6384 \\ 0.7615 & 5.5012 \\ -0.9969 & 3.1251 \\ -0.8717 & 1.4972 \\ -0.6863 & -5.5381 \\ -0.2600 & -0.8903 \\ -2.8516 & -5.6353 \\ 0.5935 & 5.7408 \\ 7.1206 & 6.8625 \\ 1.2709 & -2.6232 \\ -0.6728 & -1.6287 \end{pmatrix} \quad (5.1)$$

$$\mathbf{b}_1 = \begin{pmatrix} 2.0259 \\ 3.9097 \\ 3.9868 \\ -9.1379 \\ 0.9640 \\ -3.9404 \\ 0.7537 \\ -1.3370 \\ 3.9025 \\ -0.4637 \\ -4.9059 \\ -3.9357 \\ 2.2200 \\ 4.1452 \\ 0.9609 \end{pmatrix} \quad (5.2)$$

$$\mathbf{W}_2 = \begin{pmatrix} 0.0194 \\ -123.5025 \\ 47.8305 \\ -0.0150 \\ -16.6893 \\ 126.7897 \\ -0.0063 \\ -0.0374 \\ 156.7153 \\ 1.1191 \\ -0.0124 \\ -45.8599 \\ -0.0007 \\ 0.1540 \\ 17.1860 \end{pmatrix}^T \quad (5.3)$$

$$\mathbf{b}_2 = 0.0231 \quad (5.4)$$

Pode-se contabilizar ao todo 61 parâmetros, ou seja, o conjunto de treinamento, composto por um total de 2250 dados, foram representados pelo conjunto de parâmetros da rede neural artificial. Assim, tem-se uma taxa de compactação de quase 37 vezes.

5.6. DADOS EXTRAPOLADOS

As tabelas alcoométricas disponíveis e normatizadas possuem restrições com relação às faixas de temperatura. Dessa forma, não são disponíveis dados que permitem quantificar o quão adequado são os dados extrapolados pela rede neural artificial. Além disso, a topologia adotada, uma rede perceptron multicamadas, não deve ser empregada, de forma confiável e de uma forma geral, na extrapolação de dados.

Assim, o objetivo dessa seção fora de verificar se o comportamento da rede neural artificial não se torna errático para dados que extrapolem o domínio das variáveis das entradas. Para tanto, o domínio da temperatura, que no conjunto de treinamento ficou entre 10°C e 100°C, fora expandido para a faixa de -20°C e 120°C.

O comportamento de como o grau INPM varia em função da temperatura para diferentes valores de densidade é apresentado por meio da Figura 21.

Figura 21. Grau INPM em função da temperatura e da concentração em kg/m³.

O gráfico mostrado na Figura 22 representa o comportamento do grau INPM em função da temperatura com os valores extrapolados. Observe que a rede continuou apresentando bons resultados, mantendo-se a concentração constante, mas apenas para valores de concentração inferiores a 968 kg/m^3 .

Figura 22. INPM testado extrapolando os valores de temperatura.

Analisando os resultados obtidos, podemos concluir os estudos com o a certeza do objetivo alcançado. O trabalho apresentou um resultado de redução de espaço em memória de hardware muito expressivo

CAPÍTULO 6. CONCLUSÃO.

6.1. CONCLUSÕES

Esta dissertação teve como objetivo desenvolver o projeto de uma rede neural artificial que mapeasse o grau alcoólico do etanol para uma faixa de temperatura que extrapolasse a estabelecida pelas normas brasileiras. Essa extrapolação constitui em uma necessidade latente nos processos industriais de fabricação do álcool etílico onde a temperatura na coluna de destilação do etanol é superior aos 40°C, limite superior ao das normas brasileiras. Assim, convencionalmente, é necessário dispendir recursos, principalmente na forma de energia e tempo, para condicionar a temperatura do etanol para a faixa de temperatura prevista em norma. Essa alternativa, além de dispendir os recursos citados, resulta em um atraso na atuação do sistema de controle incorrendo em queda da eficiência da planta como um todo.

De forma alternativa são disponíveis tabelas associando temperatura e densidade com grau INPM. Essas tabelas, por sua vez, poderiam ser empregadas diretamente em sensores virtuais para quantificação do grau INPM. Contudo, as soluções disponíveis, em geral na forma de algoritmos do tipo *check-up-table*, exigem um volume de memória considerável podendo resultar no acréscimo de elementos de memória no sensor. Esse elemento, por sua vez, soma custos ao projeto, consumo de energia pelo hardware utilizado e piora da confiabilidade uma vez que sua taxa de falhas passa a ser incorporada ao sensor.

A solução apresentada nesse trabalho trouxe contribuições para esses três aspectos a serem considerados quando da implementação em dispositivos em campo para estimação do grau INPM do etanol, ou seja, trabalhar com uma faixa de temperatura condizente com o encontrado no processo industrial e com um dispêndio computacional plausível. Demonstrando, portanto que é possível e viável representar tabelas alcoométricas através de uma RNA.

Os resultados obtidos trazem uma redução significativa de tempo entre a leitura dos dados e a obtenção do resultado desejado no campo. Garantindo uma diminuição do tempo de tomada de decisões no controle do processo industrial.

Os resultados de redução de espaço em memória de hardware foram muito claros. Reduziu-se uma tabela com 2250 linhas, com três floats cada uma, para um conjunto de 61 floats apenas, ou seja, a base de dados foi reduzida em mais de 110 vezes, provando o potencial de contribuição científica que o emprego das RNA em equipamentos sensores microprocessados, pode trazer para o desenvolvimento de novos sensores inteligentes.

Em se tratando de trabalhos futuros, pode-se construir equipamentos inteligentes que seriam sensores capazes de indicar o teor de açúcar dissolvido em um xarope, ou medir a quantidade de açúcar no suco de laranja, sensores capazes de quantificar o hexano dissolvido em óleo de soja utilizados em fabricas de óleos. Inúmeras possibilidades se abem para outras aplicações que fazem uso de tabelas de controle de soluções com dois ou mais componentes e suas composições podem se beneficiar do emprego de RNA.

Trabalhos que efetuem o cálculo do tempo de processamento e desempenho entre os dois métodos, *check-up-table* e processamento matricial, também podem ser desenvolvidos. Uma vez que temos tendências a aceitar que o algoritmo proposto é mais eficiente no quesito tempo de processamento, mas não foi objeto de estudo neste trabalho.

Outra abordagem para esta solução seria a busca por arquiteturas neurais diferentes da abordada neste trabalho. Talvez inserindo neurônios em uma segunda camada escondida possa trazer melhores resultados.

Para a área de controle de processos, uma possível sugestão de trabalho seria a utilização do sinal de saída de um sensor, como proposto neste trabalho, como variável de entrada em um controle PID de uma coluna de destilação. Este estudo era difícil de ser executado por não se ter um sinal claro do grau alcoólico do etanol na saída das torres de destilação.

Bibliografia

Bibliografia consultada.

AGUIRRE, L.A. (2004). **Introdução à identificação de sistemas: técnicas lineares e não-lineares aplicadas a sistemas reais**. Belo Horizonte: Universidade Federal de Minas Gerais.

ALBUQUERQUE, A. R. L.; POLICASTRO, C. A. **Automação e controle em aparelhos de destilação de etanol: uma visão crítica**. Revista Ciência e Tecnologia, p. 21-29, 2007.

ANASTASIO, T.J., “**Tutorial on Neural Systems Modeling**”. Sinauer Associates, 2009.

ANDERSON, J.A. “**An introduction to neural networks**”. MIT Press, 1995. KOSKO, B. “**Neural Networks and Fuzzy Systems**”. Prentice-Hall, 1992.

ANP, **Cartilha do Posto Revendedor de Combustíveis**, Agência Nacional do Petróleo, Gás Natural e Biocombustíveis ANP, 5ª Edição, Rio de Janeiro, 2011. <http://www.anp.gov.br/>

ANP -**Resolução Anp Nº 7, Retificada Dou 14.4.2011**, Agência Nacional do Petróleo, Gás Natural e Biocombustíveis ANP, site disponível no site: http://nxt.anp.gov.br/nxt/gateway.dll/leg/resolucoes_anp/2011/fevereiro/ranp%207%20-%202011.xml. Acessada em Abril de 2013.

ANTHONY, M., BARTLETT, P.L., “**Neural Network Learning: Theoretical Foundations**”. Cambridge University Press, 2009.

BETTIN, H. & Spieweck, F. **A Revised Formula for the Calculation of Alcoholometric Tables**, PTB Mitteilungen 6/90, p.457,1990

BEGA, E. A.; DELMÉE G. J.; [et al.].**Instrumentação industrial**, 3 edição, Rio de Janeiro, 2006.

BRAGA, A.P; LUDERMIR, T. B. e de LEON, A. C. P. **Redes neurais artificiais: teoria e aplicações**. Livros Técnicos e Científicos Editores LTC - Livros Técnicos e Científicos, 2000.

COSTA. V. M.(2011). **Análise Das Variáveis De Entrada De Uma Rede Neural Usando Teste De Correlação E Análise De Correlação Canônica**. Dissertação (Mestrado) Instituto de Pesquisas Energéticas e Nucleares. USP,São Paulo, 2011.

COLLERE POSSETTI, G.R. ; Godoy Terada, G. ; DACIUK, R.J. ; Yutaka Ofuchi, C. ; NEVES, F.; RAMOS, d. A. L. V. ; MULLER, M. ; Fabris, J.L., **Heterogeneous measurement system based on optical fiber and ultrasonic sensors to determine ethanol concentration Sensors**, 2011 IEEE.

DAYAN, P., ABBOTT, L.F., **“Theoretical Neuroscience: Computational and Mathematical Modeling of Neural Systems”**. MIT Press, 2005.

EMERENCIANO, M. S. A., Santana R. A. C., Brito R. P., Vasconcelos L. G. S., **Aplicação de redes neurais artificiais na avaliação do comportamento da corrosão em ligas Co-Mo**, 2004.

GALUSHKIN, A.I., **“Neural Networks Theory”**. Springer, 2009.

GEHLEN C. O.; **Implementação De Uma Estrutura De Controle Indireto Da Concentração Etanol Em Uma Coluna De Destilação Híbrida**. Dissertação de mestrado, Santa Maria, RS, Brasil , 2013.

FUJIWARA E., ONO E., and. SUZUKI C. K. **Application of an Optical Fiber Sensor on the Determination of Sucrose and Ethanol Concentrations in Process Streams and Effluents of Sugarcane Bioethanol Industry**, 2011.(IEEE 06215009).

GEROMEL, L. H.(2003). **A aplicação de sistemas inteligentes de transformadores de potência** 144p. Tese (Doutorado) – Universidade Estadual de Campinas, Campinas.

HAYKIN, S. **Redes neurais: princípios e práticas**. 2.ed. Porto alegre: Bookman. 2000.

JERBIĆ, I.; Bolf, N.; Pavelić, H.. **Development of Soft Sensors for Debutanizer Product Quality Estimation and Control**. **Proceedings of European Congress of Chemical Engineering (ECCE-6)**, 2007.

LUCAS M., SILVA I. N., **Sensor Virtual Inteligente para Estimação de Composições em Colunas de Destilação**. Anais do XIX Congresso Brasileiro de Automática, CBA 2012.

MAYER, F. D.; **Desenvolvimento da tecnologia de destilação apropriada à produção de álcool combustível em pequena escala**. Dissertação de Mestrado PPGEPro, Universidade Federal de Santa Maria, Santa Maria, 2010.

McCULLOCH, W.S. , PITTS, W. **A logical calculus of the ideas immanent in nervous activity**. Bulletin of Mathematical Biophysics, vol 5, pp 115- 133. (1943)

MORAIS A. A.de Jr, **Elaboração de um analisador virtual utilizando sistema híbrido neuro-fuzzy para inferir a composição num processo de destilação**, Dissertação de Mestrado, Universidade Federal de Alagoas, 2011,

_____.NBR 5993: **Álcool etílico e suas misturas com água – Determinação da massa específica e do teor alcoólico – Método do densímetro de vidro**. Rio de Janeiro, 2008, versão corrigida 2009.

_____.NBR 15639: **Álcool etílico e suas misturas com água – Determinação da massa específica e do teor alcoólico – Método da densimentria eletrônica**. Rio de Janeiro, 2008, versão corrigida 2009.

OLIVEIRA e SOUZA, P. H. T..(2010), **Rede neural artificial para monitoramento em tempo real da concentração de potássio na vinhaça in natura**. Dissertação (Mestrado). Escola de Engenharia de São Carlos. Universidade de São Paulo, 2010.

OMEGA, E., **The Temperature Handbook**. Stamford, CT: Omega Engineering 1989. Disponível on-line: <http://www.omega.com>.

POSSETTI, G. R. C. **Sensor inteligente à fibra ótica para análise da qualidade da gasolina brasileira**, Dissertação de Mestrado Universidade Tecnológica Federal do Paraná, 2009.

POSSETTI. G. R. C., Muller M, Fabris J. L., **Refractometric optical fiber sensor for measurement of ethanol concentration in ethanol-gasoline blend**, IEEE 05427510 2009,

Reed, R. D., Marks II, R. J; **Neural smithing: supervised learnig in feedforward artificial neural networks**. MIT Press, Cambridge, Massachusetts, USA. .(1999)

RIPLEY, B.D., “**Pattern Recognition and Neural Networks**”. Cambridge University Press, 2008.

ROSSELL ,C. E. V., **Produção de Etanol de Cana-de-açúcar. Qualidade da Matéria-prima**, Grupo Energia-Projeto Etanol (MCT/NIPE). 2006. Disponível em http://www.inovacao.unicamp.br/etanol/report/workshop-etanol_carlos-rossell.pdf, acessado em 22/05/2013.

RUMEHART, D.E., HINTON, G. E., WILLIAMS, R. J. (1986); **Learning internal representations by error propagation**. In: **Parallel Distributed Processing**, vol 1, chapter 8 . MIT Press, Cambridge, Massachusetts, USA.

SANTOS. José. C. dos; SANTOS. R. P. dos; SALLES. J. L. F. **Redução da variabilidade do teor alcoólico na indústria sucroalcooleira**. ISA Show, Brasil. (2010).

SILVA, I.N., SPATTI, D.H., FLAUZINO, R. A., “**Redes Neurais Artificiais Para Engenharia e Ciências Aplicadas**”. ArtLiber Editora. (2010).

SILVA J. F.,**Especificação Internacional para Etanol Não desnaturado**. (2007);Disponível no site: http://www.inmetro.gov.br/painelsetorial/palestras/especificacaoInternational_JoseFelix.pdf

STINCHCOMBE, M. B. **Neural network approximation of continuous functional and continuous functions on compactifications neural networks**,1999.

TSOUKALAS, L.H., UHRIG, R.E.(1997), “**Fuzzy and Neural Approaches in Engineering**”. John Wiley.

WERLE, L. O.; **Implementação de Sensores por Software em Colunas de Destilação com Aquecimento Distribuído**. Qualificação de Doutorado, Universidade Federal de Santa Catarina, 2009.

ZANATA, D.R.P. **Desenvolvimento de sensor virtual empregando redes Neurais para medição da composição em uma coluna destilação**. 229p. Dissertação (Mestrado) – Escola Politécnica, Universidade de São Paulo, São Paulo, 2005.

ZARPELON. F. **As Especificações Do Álcool Focadas Para O Mercado Mundial**, EMBRAPA. 2008. Disponível no site <http://www.agencia.cnptia.embrapa.br/>

UNICA, **Coletiva de imprensa safra 2013/2014**. São Paulo 29/04/2013. link: <http://www.unica.com.br/download.php?idSecao=17&id=12655382>, acessado em Setembro de 2013.

ZUCCHINI, R. R.; THEMUDO, J. de S.; ENGELMANN, M. **A qualidade do etanol e de suas misturas com a água**, obtido em 20/08/2013.

<http://www.banasmetrologia.com.br/textos.asp?codigo=1460&secao=revista>.

Softwares utilizados neste trabalho.

Tabelas Alcomométricas, software adjunto à norma ABNT NBR 5993.

AlcoDens Versão 2.3 de setembro de 2012. Programa projetado pela Katmar Software.

Obtido no site <http://www.katmarsoftware.com/alcodens.htm>.