

UNIVERSIDADE DE UBERABA  
PRÓ-REITORIA DE PESQUISA, PÓS-GRADUAÇÃO E EXTENSÃO  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA QUÍMICA  
MESTRADO PROFISSIONAL

PAULO FERNANDO SARRETA DA SILVA

CONTROLE DE UMA COLUNA DE DESTILAÇÃO APLICANDO REDES  
NEURAIS

UBERABA-MG  
2018



PAULO FERNANDO SARRETA DA SILVA

CONTROLE DE UMA COLUNA DE DESTILAÇÃO APLICANDO REDES  
NEURAIIS

Dissertação apresentada como parte dos requisitos para obtenção do Título de Mestre em Engenharia Química do Programa de Pós-graduação em Engenharia Química -Mestrado Profissional da Universidade de Uberaba (PPGEQ-MP/UNIUBE).

Orientador:

Prof. Dr. Edilberto Pereira Teixeira

Coorientador:

Prof. Dr. Elizabeth Uber Bucek

UBERABA-MG  
2018

Catálogo elaborado pelo Setor de Referência da Biblioteca Central UNIUBE

S38c Silva, Paulo Fernando Sarreta da.  
Controle de uma coluna de destilação aplicando redes neurais / Paulo  
Fernando Sarreta da Silva. – Uberaba, 2018.  
62 f. : il. color.

Dissertação (mestrado) – Universidade de Uberaba. Programa de  
Mestrado Profissional em Engenharia Química, concentração:  
Desenvolvimento de Processos Químicos Agroindustriais.

Orientador: Prof. Dr. Edilberto Pereira Teixeira.  
Coorientadora: Profa. Dra. Elizabeth Uber Bucek.

1. Engenharia química – Destilação. 2. Destilação fracionada. 3.  
Redes neurais (Computação). I. Teixeira, Edilberto Pereira. II. Bucek,  
Elizabeth Uber. III. Universidade de Uberaba. Programa de Mestrado em  
Engenharia Química. IV. Título.

CDD 660.284.25

PAULO FERNANDO SARRETA DA SILVA

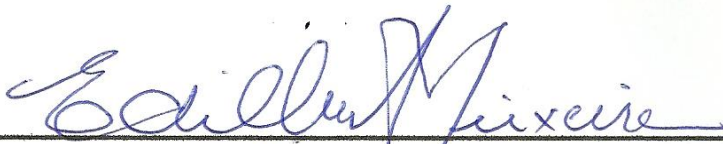
CONTROLE DE UMA COLUNA DE DESTILAÇÃO APLICANDO REDES  
NEURASIS

Dissertação apresentada como parte dos requisitos para  
obtenção do Título de Mestre em Engenharia Química  
do Programa de Pós-graduação em Engenharia  
Química -Mestrado Profissional da Universidade de  
Uberaba (PPGEQ-MP/UNIUBE).

Área de concentração: Desenvolvimento de Processos  
Químicos Agroindustriais.

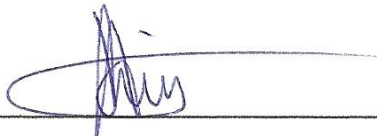
Aprovada em 29/09/2018

BANCA EXAMINADORA:



---

Prof. Dr. Edilberto Teixeira - Orientador  
Universidade de Uberaba



---

Prof. Dr. Leonardo Campos Assis  
Universidade de Uberaba



---

Prof. Dr. Antônio Luís de Oliveira  
Faculdade de Filosofia, Ciências e Letras



À memória de meu pai – Joaquim Donizetti da Silva que provou ser o melhor homem e pai que já conheci, por acreditar cegamente em mim e por ter abdicado de sua vida em prol das realizações e da felicidade de seus filhos.





## Agradecimentos

Início meus agradecimentos por DEUS, porque sei que tudo nesse mundo só acontece com a sua permissão e pela dádiva da vida e por me permitir realizar tantos sonhos.

Agradeço a todas as pessoas que confiaram em mim e me deram o seu apoio. Entre tantos, vale destacar os mais marcantes.

Agradeço ao meu pai, Joaquim Donizetti da Silva, e minha mãe, Liliana Sarreta da Silva que em algum momento de seus passados optaram por me dar esta oportunidade de vir ao mundo e poder mostrar minhas qualidades. Sempre me apoiaram e em momento nenhum desistiram de mim, jamais. Tenho que agradecer a minha vó, Lélia Sarreta, que mesmo não tendo o conhecimento técnico na área sempre confiou em mim, até nos momentos nos quais nem eu mesmo acreditava. Agradeço aos meus irmãos, André Luiz Sarreta da Silva e Ana Paula Sarreta da Silva, por me aguentarem quando as coisas não deram certo e o nervosíssimo vinha à tona. Agradeço às pessoas que indiretamente estão ligados a mim, Sônia, Vicente, Laura, Lili, Olga, Augusto, por me permitirem continuar sonhando. Agradeço ao meu orientador, Dr. Edilberto, ao Dr. Marcelo e a Dra. Elizabeth que me permitiram ter o prazer de poder aprender com os melhores. Por último e não menos importante agradeço a minha alma gêmea Caroline Rodrigues, que por noites a fio e posso dizer por dias também, segurando minha mão e dizendo confio em você. Quando mais precisei foi ela quem esteve lá, casa comigo?



*“Alguns homens veem as coisas como são,  
e dizem ‘Por que?’ Eu sonho com as coisas  
que nunca foram e digo ‘Por que não?’”*

*(George Bernard Shaw)*



## Resumo

Este trabalho apresenta a modelagem de uma rede neural artificial (RNA) para controle de uma coluna de destilação genérica, por meio de simulações. O controle PID é caracterizado por uma técnica de controle de processos que une as ações derivativa, integral e proporcional, fazendo assim com que o sinal de erro seja minimizado pela ação proporcional, zerado pela ação integral e obtido com uma ação antecipatória pela parcela derivativa. Este tipo de controle é muito difundido e consolidado nas indústrias. Propõe-se, neste trabalho, mesclar o controle PI, ação proporcional e integral, com uma rede neural de forma a utilizar a sua capacidade preditiva. Foi realizada a modelagem e o treinamento da rede que, posteriormente, foi utilizada para prever estados futuros da coluna analisada. Desta forma, além de se eliminar o erro de regime permanente, obtém-se um comportamento transitório com baixa variabilidade. A coluna de destilação utilizada foi uma coluna de 41 estágios com a alimentação feita no estágio 21 e separando uma mistura binária com volatilidade relativa de 1,5 em produtos de 99% de pureza de topo. Trata-se de um modelo não-linear com múltiplas entradas e múltiplas saídas. Foi verificado que o controlador neural apresentou um tempo de acomodação, em média, 33% menor e um overshooting, em média 0,11% menor.

**Palavras-chave:** rede neural artificial; coluna de destilação; controle não-linear; PID; MATLAB.



## Abstract

This work presents the modeling of an artificial neural network (RNA) for the control of a generic distillation column, by simulations. The PID control is characterized by a process control technique that combines derivative, integral and proportional actions, thus making the error signal minimized by proportional action, zeroed by the integral action and obtained with an anticipatory action by the derivative parcel. This type of control is very widespread and consolidated in industries. It is proposed, in this work, to merge PI control, proportional and integral action, with a neural network to use its predictive capacity. The modeling and training of the network was performed, which was later used to predict future states of the analyzed column. Thus, in addition to eliminating the steady state error, we obtain a transient behavior with low variability. The distillation column used was a 41-stage theoretical column with the feed done in stage 21, by separating a binary mixture with relative volatility of 1.5 in products of 99% top purity. It is a nonlinear model with multiple inputs and multiple outputs. It was verified that in addition to the ease of implementation. In comparison to the PID, the neural controller presented an average accommodation time of 33% lower and an average overshooting 0.11% lower.

**Keywords:** artificial neural network; distillation column; non-linear control; PID; MATLAB.





## Lista de ilustrações

Figura 1 - Neurônio Humano.....	4
Figura 2 - Neurônio Artificial.....	6
Figura 3 - Função linear.....	7
Figura 4 - Função degrau ou limiar .....	7
Figura 5 - Função rampa.....	8
Figura 6 - Função sigmoide .....	9
Figura 7 - Arquitetura uma camada.....	10
Figura 8 - Arquitetura múltiplas camadas .....	10
Figura 9 - Arquitetura Recorrente .....	11
Figura 10 - Exemplo de retroalimentação .....	12
Figura 11 - Sistema não linearmente separável.....	13
Figura 12 Esquemático de uma coluna de destilação com seus componentes básicos ..	20
Figura 13 Desenho esquemático dentro da coluna de destilação .....	22
Figura 14 - Modelo Skogestad Coluna – LV.....	23
Figura 15 - Sinais randômicos inseridos .....	26
Figura 16 - Definição RNA .....	27
Figura 17 - Resultado Treinamento .....	27
Figura 18 - Erro da RNA .....	28
Figura 19 - Treinamento RNA.....	29
Figura 20 - Resposta da Saída .....	29
Figura 21 - Bloco criado da RNA.....	30
Figura 22 - RNA prevendo saída.....	30
Figura 23 - Controle PI.....	31
Figura 24 - Saída $y_1$ com controlador PI.....	32
Figura 25 - Controle neural .....	33
Figura 26 - Gráfico controle Rede Neural .....	34
Figura 27 - Gráfico comparativo - $Y_1$ .....	34
Figura 28 - Sinal randômico aplicado na entrada - Vazão Refluxo.....	40
Figura 29 - Sinal randômico aplicado na entrada - Vazão Refervedor .....	40
Figura 30 - Sinal randômico aplicado na entrada - Vazão Topo .....	41
Figura 31 - Sinal randômico aplicado na entrada - Vazão Fundo .....	41



Figura 32 - Composição topo - Y1 .....	42
Figura 33 - Composição fundo - Y2.....	42
Figura 34 - Taxa Condensador - Y3 .....	43
Figura 35 - Taxa refervedor - Y4.....	43
Figura 36 - Composição de fundo com Rede Neural .....	44
Figura 37 – Composição de fundo só com PI.....	44
Figura 38 - Comparação Rede e PI.....	45



## Lista de tabelas

Tabela 1 - Valores das entradas na coluna .....	24
Tabela 2 – Composição de Topo só PI.....	35
Tabela 3– Composição de Topo com rede neural .....	35
Tabela 4 – Composição Fundo com rede neural .....	45
Tabela 5– Composição Fundo só PI.....	45



## Lista de símbolos

$x_1, x_2, \dots, x_m$	vetor entrada $x$ e $1, 2, m$ seus valores
$v_k$	somador
$b_k$	bias
$w_{k1}, w_{k2}, \dots, w_{km}$	vetor entrada $w$ e $k1, k2, km$ seus valores
$y_k$	saída do neurônio $k$
$F(v_k)$	função de ativação
$\Delta\omega_{ij}$	valor da modificação do neurônio $i$ ao neurônio $j$
$\eta$	parâmetro de aprendizagem
$E_j$	erro no neurônio $j$
$O_i$	saída do neurônio $i$ do qual parte a ligação
$E_j$	erro no neurônio $j$
$V_j$	saída desejada
$O_j$	saída real do neurônio $j$
$g'$	derivada da função de ativação
$(I_j)$	entrada da rede no neurônio $j$
$\omega_{ij}$	peso entre neurônio $i$ e $j$
$E_j$	erro no neurônio $j$
$L$	<i>vazão de refluxo</i>
$V$	<i>vazão do refervedor</i>
$D$	<i>vazão de topo (produto final)</i>
$B$	<i>vazão de fundo (produto de fundo)</i>
$zF$	<i>composição da alimentação</i>





$F$	<i>taxa de alimentação</i>
$qF$	<i>fração líquida da alimentação</i>
$y(1)$	<i>composição de topo</i>
$y(2)$	<i>composição de fundo</i>
$y(3)$	<i>taxa do condensador</i>
$y(4)$	<i>taxa do refeedor</i>
$y(5)$	<i>composição da bandeja de topo e fundo</i>
T1 até T9	sensores de Temperatura
V1 até V12	válvulas
FI1	rotâmetro
$y_j(n)$	saída produzida por um neurônio
$F(y_i)$	Função de ativação
$s_j(n)$	resposta desejada para o neurônio j
$y_j(n)$	saída produzida pelo neurônio j.
$E = \sum_j e_j(n)$	soma dos erros quadráticos
$\Delta w_{kj}$	Valores dos pesos modificados
$\delta e_j$	Derivada do erro no neurônio j
$\delta w_{kj}$	Derivada do neurônio j
$w_{kj}$	Peso do neurônio j
$w_{kj}^{k+1}$	Peso do neurônio j atualizado



## Sumário

1 - Introdução.....	1
1.1 Objetivos .....	3
1.2 Objetivos Específicos .....	3
2 - Introdução a Redes Neurais Artificiais .....	4
2.1 O cérebro Humano.....	4
2.2 O que é uma rede neural artificial.....	4
2.3 Modelo matemático de um neurônio .....	5
2.4 Tipos de Função de ativação.....	7
2.5 Arquiteturas das Redes Neurais .....	9
2.5.1 Redes de Uma Camada (Feedforward).....	9
2.5.2 Redes de Múltiplas Camadas (Feedforward) .....	10
2.5.3 Redes Recorrentes (Feedback).....	11
2.6 Aprendizagem .....	11
2.6.1 Aprendizagem Supervisionada .....	11
2.6.2 Treinamento não Supervisionado .....	12
2.6.3 Aprendizagem com reforço .....	12
2.7 Perceptrons de Múltiplas Camadas.....	12
2.8 Algoritmo de Retropropagação.....	13
2.12 Processo de Treino – Retropropagação .....	15
3 – Coluna de Destilação .....	18
3.1 Processos de separação .....	18
3.2 Princípios da destilação.....	18
3.3 Colunas de Destilação.....	19
3.4 Princípio de Funcionamento .....	19
4 – Metodologia.....	23
4.1 - Modelo da Coluna de Destilação.....	23
4.2 – Treinamento da Rede Neural .....	25
4.3 – Controle usando rede neural .....	25
5 – Resultados e Discussões .....	26
5.1 - Controle PI.....	31
5.2 – Rede Neural Preditiva .....	33
Conclusão .....	36
Bibliografia.....	37



Anexo(s) .....	39
Anexo A – Aspecto do programa .....	39
Anexo B – Gráficos das entradas e saídas da coluna de destilação .....	40
Anexo C – Análise da Saída de Composição de Fundo .....	44



## 1 - Introdução

Na indústria química uma das dificuldades é realizar o controle dos processos, além do mais, essa complexidade está atrelada às crescentes demandas da sociedade incluindo qualidade, segurança e requisitos ambientais, exigidos pela legislação, cada vez mais restritiva.

Para o atendimento a essas demandas mais e mais equipamentos são interpostos ou conectados aos já existentes, aumentando a sua complexidade (ABIQUIM, 2018). Paralelamente a isso, as indústrias também têm buscado maior confiabilidade e precisão na monitoração dos processos, através da implementação de metodologias de controle inteligente para poder reduzir os custos totais e conseguir manter-se competitiva no ambiente empresarial globalizado. É nesse aspecto relativo ao controle avançado de processos que esta dissertação se baseia.

O processo de destilação visa a separação de misturas contendo diversos componentes. Esta separação ocorre devido à diferença de volatilidade de cada componente químico presente na coluna. Durante o processo, a fase líquida em contato com o vapor a uma dada temperatura e uma dada pressão, fornece a transferência de massa simultânea entre as duas fases (FOUST et al., 1982).

A maioria dos processos químicos é caracterizada por apresentar severas não-linearidades, por exemplo, colunas de destilação com alta pureza, processos bioquímicos, reatores de leito fixo, entre outros. Mesmo que o processo seja operado em uma faixa linear, a presença de um sistema de controle (atuadores, válvulas de controle, sensores) causa o surgimento de não-linearidades.

Tradicionalmente, esse tipo de controle não-linear tem sido feito aplicando a teoria de controle linear. A linearização é feita a partir de um estado estacionário de referência e o sistema de controle, projetado desta maneira, é usado no controle do sistema real que não é linear. Se o processo for operado continuamente no estado projetado, no qual houve a linearização, o modelo linear obtido se aproxima muito do processo real. Porém, é comum que as condições operacionais do processo mudem com o tempo, dependendo de diversos valores como qualidade da matéria prima, desativação de catalisadores, substituição e/ou desgaste de equipamentos. Essa nova condição leva a desvios do modelo

obtido e o controle passa a não ser mais eficiente, causando instabilidade, perda de rendimento, offsets etc.

Tendo em vista tal problema, houve a necessidade de desenvolver uma teoria de controle que levasse em conta as não-linearidades do processo. Uma condição fundamental para a teoria de controle linear é que o modelo seja realmente representativo do processo. Apesar de ser utilizado em muitas áreas, os modelos apresentam relativa complexidade, tanto para serem criados, como para serem utilizados em tempo real para controladores avançados. Desse modo, desenvolveram-se diversas metodologias mais simples, conhecidas como identificação de sistemas. Tais metodologias são muito úteis em processos complexos para os quais o processo de modelagem do sistema seria uma tarefa muito complicada ou demoraria muito tempo, sendo inviável financeiramente.

Por isso, a rede neural foi adotada neste estudo pela sua característica em captar não-linearidades, considerando-se a relação entre o estímulo de entrada e a resposta de saída.

A teoria de controle que leva em consideração modelos não-lineares, embora seja bem explorada na engenharia química, há ainda muitas aplicações a serem trabalhadas, devido à grande diversidade de processos. Com base nas afirmações acima, verifica-se que existe um terreno a ser explorado no controle de processos químicos.

No capítulo 2 foi explicado como funciona uma rede neural, quais as características e modelo a ser utilizado, seguido da modelagem de uma rede neural aplicada ao controle de uma coluna de destilação genérica.

O capítulo 3 abordou o funcionamento de uma coluna de destilação como suas características, processos e etapas a serem seguidos para que a rede neural possa se adaptar. No anexo A, foi descrito um breve resumo sobre a ferramenta computacional utilizada. No capítulo 4, foram discutidos os dados obtidos, a verificação se a rede neural implementada teve um desempenho satisfatório no controle e a análise das não-linearidades do processo. No capítulo 5, a conclusão mostra as vantagens e desvantagens de aplicar rede neural neste processo químico específico.



## 1.1 Objetivos

O objetivo principal deste trabalho é a aplicação de uma rede neural artificial (RNA) multicamada que possa realizar o controle de uma coluna de destilação fracionada na configuração LV, sem linearização.

## 1.2 Objetivos Específicos

Para atingir o objetivo principal foi necessário estabelecer alguns objetivos específicos como, dificuldade de implementação de um controlador baseado em rede neural artificial, configurar a vantagem de aplicar uma rede neural artificial em um processo químico não-linear, além de analisar o desempenho e a confiabilidade desse método de controle avançado em comparação com controlador PID, muito difundido na indústria.

## 2 - Introdução a Redes Neurais Artificiais

### 2.1 O cérebro Humano

O estudo do cérebro humano vem do interesse sobre como ele processa, lida com as informações vinda de vários lugares do corpo, com a capacidade de organizar sua estrutura neuronal e de como ele é capaz de reconhecer padrões rapidamente. Nosso cérebro é composto de aproximadamente 100 bilhões de neurônios no córtex humano e 60 trilhões de conexões entre eles (ROBERTO LEN, 2004). As conexões entre os neurônios são chamadas de sinapses.

Uma sinapse é uma conexão simples, que pode impor ao neurônio de receber um estímulo, que pode excitá-lo ou inibi-lo, mas não pode provocar os dois efeitos ao mesmo tempo.

A Figura 1 mostra o tipo mais comum de neurônio no córtex humano.

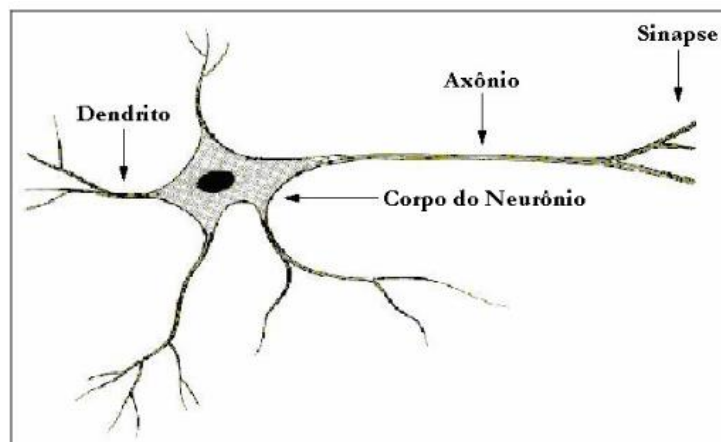


Figura 1 - Neurônio Humano  
Fonte: (CARVALHO, 2009)

Os estímulos vêm por meio dos dendritos, passa pelo corpo do neurônio, responsável por coletar e combinar informações vindas de outros neurônios, segue para o axônio e posteriormente vai para o neurônio vizinho, através da Sinapse.

### 2.2 O que é uma rede neural artificial

Inteligência artificial (IA) é uma área de estudo que abrange diferentes campos da ciência para simular a inteligência humana por software (BLANCHARD et al.2000). As redes neurais são também uma forma de inteligência artificial e que podem ser utilizadas

para resolução de problemas complexos. Elas foram desenvolvidas por com semelhança à inteligência humana com o principal objetivo de dar aos computadores a capacidade de aprender pela experiência. Ela depende de ensinarmos como a rede deverá agir em certos casos, portanto há a necessidade da aprendizagem que pode ser supervisionada ou não. Ela consiste no mapeamento da entrada e da saída com os pesos sinápticos, para adequar as saídas com as entradas. A rede neural pode se adaptar também em um meio no qual ela não foi treinada, mas é crucial analisar as variações para que o sistema possa ignorar as variações ocasionais.

Como em um cérebro humano, os neurônios da rede estão interligados uns com os outros e todos os neurônios são afetados pela atividade da rede. Caso exista um erro com algum neurônio ele irá afetar a rede inteira, porém ela é capaz de identificá-lo e corrigi-lo.

### 2.3 Modelo matemático de um neurônio

O primeiro modelo de neurônio artificial (MCCULLOCH, PITTS, 1943) desenvolvido é também o mais básico e serviu como inspiração para os demais.

Sendo o neurônio uma unidade de processamento de informação fundamental para a operação da rede neural, pode-se identificar três elementos básicos no modelo.

**Sinapse:** Conexão de uma entrada com um peso. Uma sinapse  $m$ , que está conectada a um neurônio  $k$ , recebe um sinal  $x_m$  que é multiplicado por um peso  $w_{km}$ . Os pesos definem a importância dos sinais de entrada naquela região.

**Somador:** Combinação linear, que realiza o somatório ponderado das entradas.

**Função de ativação:** É uma função que restringe a amplitude do sinal de saída e que a condiciona dentro de um determinado limiar pela soma ponderada das entradas. Esta pode ter diferentes representações.

O modelo artificial mostrado na Figura 2 é uma generalização do modelo de McCulloch e Pitts (1943). Este modelo possui um sinal adicional bias ( $b_k$ ), que favorece ou limita a possibilidade de ativação do neurônio.  $x_i$  são entradas do neurônio ( $k$ ),  $w_{ki}$  são os pesos sinápticos do neurônio  $k$  de cada entrada  $i$ ,  $F(v_k)$  é a função de ativação do neurônio,  $y_k$  é a saída e  $v_k$  é o sinal de potencial ativação da função de ativação.

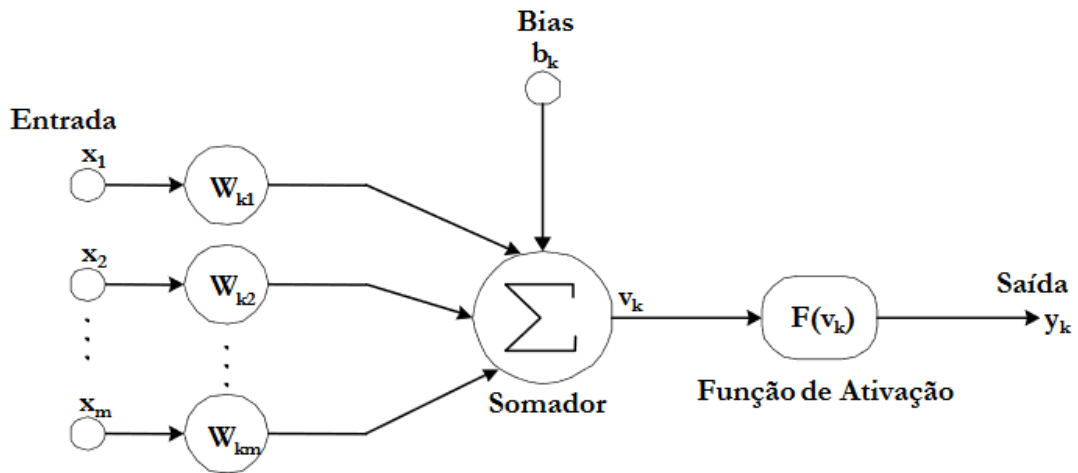


Figura 2 - Neurônio Artificial  
Fonte: (CARVALHO, 2009)

O neurônio pode ser descrito matematicamente a seguir.

$$y_k = F(v_k) \quad \text{Eq. 2.3.1}$$

Sendo:

$$v_k = \sum_{j=1}^m w_{kj} \cdot x_j + b_k \quad \text{Eq. 2.3.2}$$

Sendo:

$x_1, x_2, \dots, x_m$	Vetor entrada $x$ e 1, 2, $m$ seus valores
$v_k$	Somador
$b_k$	Bias
$w_{k1}, w_{k2}, \dots, w_{km}$	Vetor entrada $w$ e $k1, k2, km$ seus valores
$y_k$	Saída do neurônio $k$
$F(v_k)$	Função de ativação

## 2.4 Tipos de Função de ativação

A função de ativação determina a saída de um neurônio. Existem quatro tipos básicos. São eles: Linear, limiar, rampa e sigmoide. A escolha vai depender dos objetivos do projeto.

A função linear está representada na Figura 3




Figura 3 - Função linear

Definida pela equação 2.4.1

$$F(v_k) = v_k \quad \text{Eq.2.4.1}$$

A função limiar está representada na Figura 4




Figura 4 - Função degrau ou limiar

Definida pela equação abaixo

$$F(v_k) = \begin{cases} 0, & v_k < 0 \\ 1, & v_k \geq 0 \end{cases} \quad \text{Eq.2.4.2}$$

A função rampa está ilustrada na Figura 5




Figura 5 - Função rampa

Definida pela equação abaixo

$$F(v_k) = \begin{cases} 0, & v_k \leq -s \\ \sum_{j=1}^m w_{kj} \cdot x_j + b_k, & -s < v_k < +s \\ 1, & v_k \geq +s \end{cases} \quad \text{Eq. 2.4.3}$$

É idêntico a função linear em uma faixa  $[-s, +s]$  e saturada, valores invariantes, fora desta faixa.

A função sigmoide está ilustrada na Figura 6 a qual é caracterizada como uma função crescente, que mostra um equilíbrio entre o comportamento linear e não-linear.




Figura 6 - Função sigmoide

Definida pela equação abaixo

$$F(v_k) = \frac{1}{1 + e^{(-v_k T)}} \quad \text{Eq.2.4.4}$$

A variável "T" determina a inclinação da sigmoide. Quando T tende a zero, a função apresenta a característica de uma função limiar, onde  $e = 2,718281$  é o número de Euler e "T" é a constante de inclinação da sigmoide.

## 2.5 Arquiteturas das Redes Neurais

Estabelecer a arquitetura de uma rede neural é necessário em razão de que seu arranjo dependa da situação ao qual o problema está inserido e como será tratado por esta rede. Por isso a arquitetura da rede está intrinsecamente ligada ao algoritmo de aprendizagem, que é utilizado em seu treinamento (HAYKIN, 1999). Em linhas gerais podemos dizer que existem três tipos. Os agrupamentos são baseados na maneira como os neurônios são conectados no cérebro humano (B.KRÖSE, SMAGT, 1996), de forma que as informações possam ser processadas de forma dinâmica ou interativa. A topologia pode ser de redes diretas (Feedforward) ou de redes recorrentes (Feedback).

### 2.5.1 Redes de Uma Camada (Feedforward)

São redes determinadas por apenas uma linha de neurônios, que recebem as informações simultaneamente, como na Figura 7. Essa linha pode receber o nome de

camada. Esse tipo de rede é indicado para a solução de problemas linearmente separáveis (HAYKIN, 1999). Também não há uma realimentação. Os tipos que fazem parte de uma rede com uma camada pode ser: Perceptron e Adaline.




Figura 7 - Arquitetura uma camada

### 2.5.2 Redes de Múltiplas Camadas (Feedforward)

São redes que possuem um só sentido de fluxo igual a rede de uma camada, a diferença seria nas camadas ocultas, Figura 8, que são as camadas capazes de realizar problemas mais complexos. Temos os tipos: Perceptron Multicamadas, Redes de Base Radial.




Figura 8 - Arquitetura múltiplas camadas

Uma rede precisa de no máximo duas camadas intermediárias, pode produzir qualquer resultado/mapeamento (HAYKIN, 1999). Entretanto com uma única camada intermediária é suficiente para poder aproximar qualquer função contínua, conforme (Cybenko et al. 1989) demonstrou. A Figura 8 mostra uma rede de múltiplas camadas.



### 2.5.3 Redes Recorrentes (Feedback)

Suas saídas são realimentadas como sinais de entrada para outros neurônios, sendo assim empregadas para o processamento de sistemas variantes no tempo. São empregadas em previsões de séries temporais, otimização, identificação de sistemas e controle de processos. Este tipo de rede é chamada de rede recorrente, Figura 9, a qual diferencia da feed-forward por possuir conexões de realimentação (HAYKIN, 1999). Tipos: Hopfield e perceptron multicamadas com realimentação.




Figura 9 - Arquitetura Recorrente  
Fonte (PALMIERE, 2016)

## 2.6 Aprendizagem

A finalidade da aprendizagem é determinar os pesos associados aos neurônios da rede neural, de modo que ela aprenda determinada função, chamada de algoritmo de aprendizagem.

Existem diversos tipos de algoritmos de aprendizagem e o que os distingue de seus diversos tipos é o modo pelo qual o ajuste de pesos é feito. Isso é feito apresentando padrões a esta rede e em um processo iterativo os pesos tendem a adaptar-se para definir a saída, adquirindo assim o conhecimento do ambiente.

### 2.6.1 Aprendizagem Supervisionada

É um método de aprendizagem que consiste em uma relação aluno – professor. O professor possui o conhecimento e tenta repassá-lo para o aluno, rede neural artificial,

sobre determinado aspecto. Portanto a rede usa este conhecimento como orientação para se ajustar e poder produzir o mesmo resultado que o professor. Esse ajuste é feito através da soma dos erros quadráticos das saídas da rede. O algoritmo de retropropagação é o mais utilizado. A Figura 10 mostra um esquemático da aprendizagem supervisionada.

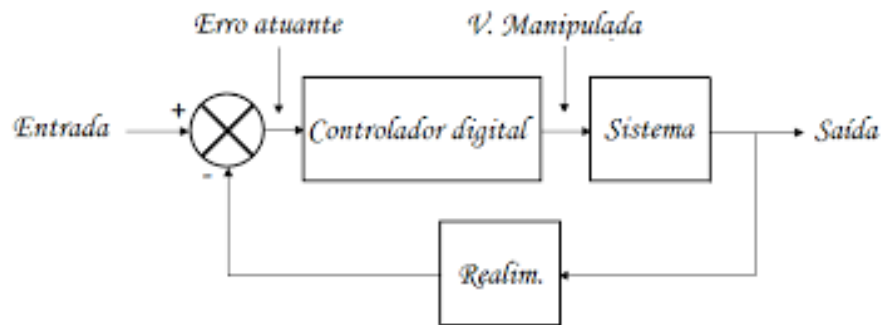


Figura 10 - Exemplo de retroalimentação  
Fonte: (MADEIRA, 2016)

### 2.6.2 Treinamento não Supervisionado

Deve-se dispor das amostras e das respectivas saídas desejadas para que os pesos e limiares sejam ajustados continuamente pelo algoritmo de aprendizagem.

### 2.6.3 Aprendizagem com reforço

Similar ao treinamento supervisionado, contudo seu algoritmo visa ajustar os pesos e limiares baseando-se em informações procedentes da interação com o sistema mapeado, visando reforçar as respostas satisfatórias.

## 2.7 Perceptrons de Múltiplas Camadas

As redes multicamadas utilizando unidades de processamento do tipo perceptron (GUYON I.,1991). Uma rede de múltiplas camadas tem pelo menos uma camada intermediária. Ela possui a característica de poder tratar dados que não são linearmente separáveis. Figura 11.




Figura 11 - Sistema não linearmente separável  
Fonte: (PALMIERE, 2016)

Conforme a Figura 8, podemos dividir esta rede em três grupos de camadas: a camada de entrada, a camada oculta e a camada de saída. Por conta dessa camada oculta a rede é capaz de aproximar qualquer função contínua. Para treinarmos essa rede usamos o algoritmo que se baseia na regra de aprendizagem da soma dos erros quadráticos, o qual chamamos de retropropagação. A lei de aprendizagem é utilizada a regra Delta.

## 2.8 Algoritmo de Retropropagação

O algoritmo de retropropagação é um algoritmo de treinamento supervisionado que baseia seu funcionamento em resoluções iterativas. Este algoritmo tem dois procedimentos básicos: a propagação linear no sentido da entrada para a saída e a propagação no sentido inverso que é a do erro gerado pela saída. O erro pode ser classificado como sendo a diferença entre o padrão esperado e a saída real do sistema. Através desse erro a rede pode ir ajustando os pesos até conseguir zerá-lo.

O algoritmo será descrito abaixo.

Passo 1:

Inicializam-se os pesos da rede com valores aleatórios, diferentes de zero.

Passo 2:

Mostrar para a rede as saídas desejadas, a partir daí inicia-se as iterações e calcula-se os erros. Através do erro calcula-se novos pesos e o processo inicia-se novamente.

Para modificação dos pesos no algoritmo utiliza a regra delta.

$$\Delta\omega_{ij} = \eta \times E_j \times O_i \quad \text{Eq.2.11.1}$$

$\Delta\omega_{ij}$  é o valor da modificação do neurônio  $i$  ao neurônio  $j$

$\eta$  é o parâmetro de aprendizagem

$E_j$  é o erro no neurônio  $j$

$O_i$  é a saída do neurônio  $i$  do qual parte a ligação

O cálculo do erro é a função da diferença entre a saída desejada e a saída real do neurônio.

Assim o erro em um neurônio  $j$  na última camada é:

$$E_j = (V_j - O_j) \times g'(I_j) \quad \text{Eq.2.11.2}$$

$E_j$  = Erro no neurônio  $j$

$V_j$  = Saída desejada

$O_j$  = Saída real do neurônio  $j$

$g'$  = derivada da função de ativação

$(I_j)$  = Entrada da rede no neurônio  $j$

O erro de um neurônio  $i$  de uma camada oculta  $m$  é:

$$E_i^{m-1} = \sum_j (\omega_{ji} \times E_j^m) \times g'(I_i^m) \quad \text{Eq.2.11.3}$$

$\omega_{ij}$  = Peso entre neurônio  $i$  e  $j$

$E_j$  = Erro no neurônio  $j$

## 2.12 Processo de Treino – Retropropagação

Basicamente o algoritmo consiste em dois passos de computação. O processamento direto e reverso. No direto, uma entrada é aplicada à rede neural e seu efeito é propagado pela rede. Durante este processo os pesos permanecem fixos. No reverso um sinal de erro calculado na saída da rede é propagado no sentido reverso e ao final deste processo os pesos são ajustados de acordo com uma regra de correção do erro. A seguir segue o exemplo de implementação desse algoritmo.

– Inicialização dos pesos

Inicialize os pesos da rede aleatoriamente em um intervalo pequeno ou segundo algum método mais refinado proposto na literatura.

– Escolha do padrão a ser ensinado para rede

– Propagação do padrão

A saída produzida por um neurônio é descrita a seguir.

$$y_j(n) = F(y_j) = F\left(\sum_{j=1}^m w_{kj} \cdot x_j + b_k\right) \quad \text{Eq.2.12.1}$$

Sendo:

$y_j(n)$  saída produzida por um neurônio

$b_k$  Bias

$w_{k1}, w_{k2}, \dots, w_{km}$  Vetor entrada  $w$  e  $k1, k2, km$  seus valores

$F(y_i)$  Função de ativação

– Cálculo dos erros na última camada

O sinal de erro na saída do neurônio  $j$ , na iteração  $n$ , é definido por:

$$e_j(n) = s_j(n) - y_j(n) \quad \text{Eq.2.12.2}$$

Onde:

$s_j(n)$  resposta desejada para o neurônio  $j$  da camada de saída.

$y_j(n)$  saída produzida pelo neurônio  $j$ .

Segundo (JR.; CRUZ, 1998) pode-se concluir que o erro gerado é a soma dos erros quadráticos.

$$E = \sum_j e_j(n) = \frac{1}{2} \sum_j (s_j(n) - y_j(n))^2 \quad \text{Eq.2.12.3}$$

Onde:

$E = \sum_j e_j(n)$  soma dos erros quadráticos

– Lei de aprendizagem para alterar os pesos

Utilizando a técnica do gradiente decrescente, os valores são modificados ao oposto da derivada do erro.

$$\Delta w_{kj} = -\eta \frac{\delta e_j}{\delta w_{kj}} \quad \text{Eq.2.12.5}$$

$$w_{kj}^{k+1} = w_{kj} + \Delta w_{kj} \quad \text{Eq.2.13.6}$$

Sendo:

$\Delta w_{kj}$  Valores dos pesos modificados

$\eta$  Taxa de aprendizagem

$\delta e_j$  Derivada do erro no neurônio  $j$

$\delta w_{kj}$  Derivada do neurônio  $j$

$w_{kj}$ 

Peso do neurônio j

 $w_{kj}^{k+1}$ 

Peso do neurônio j atualizado

– Reinício

Reinício, até o padrão ser aprendido ou até a regra de parada de iteração por uma determinada condição de convergência for atingido como, por exemplo, um limiar aceitável para o erro (tolerância).

## 3 – Coluna de Destilação

### 3.1 Processos de separação

O processo de destilação é um processo baseado em separação de substâncias mais utilizado na indústria química, por intermédio dela conseguimos separar substâncias que formam uma determinada mistura através do seu aquecimento. (MCCABE et al. 1993).

Várias substâncias com diferentes propriedades químicas e físicas são produzidas todos os dias por processos que envolvem reações químicas em vários ramos, como as indústrias químicas, farmacêuticas e petroquímicas. Em consequência, grande parte dos processos geram produtos e subprodutos, desejáveis ou não. Necessitando assim a sua separação por meios apropriados economicamente e ambientalmente, mas sempre com o foco de obter um alto índice de pureza do produto principal.

Existem várias técnicas de separação difundidas atualmente que são provenientes de estudos e observações experimentais, visando a simplificação e unificação dos processos (MCCABE et al. 1993). Na presente dissertação foi dado destaque no processo de operações unitárias, sendo a destilação como foco para estudo.

### 3.2 Princípios da destilação.

As operações unitárias mais conhecidas e utilizadas atualmente em escala global é a destilação de misturas. Nas indústrias, misturas com vários componentes com diferentes volatilidades ou pontos de ebulição, são separados aquecendo essa mistura.

Esta técnica vem sendo utilizada ao longo dos milhares de anos. A aplicação mais antiga e conhecida é para a preparação de bebidas alcoólicas. Com o passar dos anos houve a necessidade de aperfeiçoar e aumentar a escala de produção levando a uma escala industrial, gerando assim estudos para outras áreas, produtos e aplicações (KISTER, 1992).



### 3.3 Colunas de Destilação

Uma coluna de destilação é composta de um tubo cilíndrico vertical, no qual sua construção depende das substâncias presentes em seu interior, da temperatura e da pressão do processo. Ela é projetada para permitir o máximo de contato, para a transferência de calor e de massa entre as fases.

Faz parte da coluna um refeedor, localizado na parte inferior, utilizado para promover a vaporização da mistura e um condensador no topo para o vapor que sai da coluna. Também pode existir acoplado ao condensador um decantador para armazenar o vapor condensado para bombear parte do material de volta para dentro da coluna.

### 3.4 Princípio de Funcionamento

O princípio básico de funcionamento é baseado no aquecimento de uma mistura, para entrar em ebulição o componente mais volátil e assim acontecer a separação.

Quanto mais volátil a substância mais fácil para ela vaporizar, portanto se as diferenças de volatilidade forem maiores, mais fácil será a separação. Nesta dissertação foi empregado uma coluna de destilação de duas substâncias genéricas. Vamos chamar estas duas substâncias de “Substância A” e “Substância B”

A Figura 12 mostra o desenho esquemático de uma coluna de destilação com seus componentes básicos anexados.

A mistura que vamos separar está armazenada dentro dos “tanques de alimentação”, através da “bomba de alimentação”, ela será bombeada até um trocador de calor no qual acontecerá um pré-aquecimento até uma temperatura ideal para o processo, para só assim poder alimentar a coluna com esta mistura. O sensor  $T$  faz a verificação da temperatura ideal para a alimentação da coluna.

A coluna de destilação utilizada como exemplo está na Figura 13 e é composta por 8 pratos cada um com o seu sensor de temperatura que vai do  $T1$  ao  $T8$ . Na parte inferior da coluna existe um aquecedor elétrico que tem a função de aquecer a mistura até ela entrar em ebulição, para poder acontecer a separação, o sensor que faz a leitura e controle dessa temperatura é o sensor  $T9$ . Embaixo do aquecedor existe uma válvula ( $V2$ ) que permite a coleta de uma amostra do possível produto de fundo.

A alimentação é realizada no estágio 21 da coluna. Essa mistura escoá até chegar na seção de estripagem, que é definida pelos primeiros 4 pratos de baixo para cima. Com a resistência ligada a mistura começa a aquecer e as substâncias que a compõe entram em ebulição. Vamos supor que a substância A é mais volátil que a substância B, portanto ela entra em ebulição primeiro e passa para o estado de vapor, como o vapor é menos denso que a mistura líquida dentro da coluna, acontece um processo ascendente do fluxo de vapor e um outro processo de fluxo descendente do condensado. Com isso o vapor sobe e vai para a seção de retificação, definido pelos pratos onde os sensores  $T1$ ,  $T2$ ,  $T3$  e  $T4$  estão localizados.

Como mostra a Figura 12.

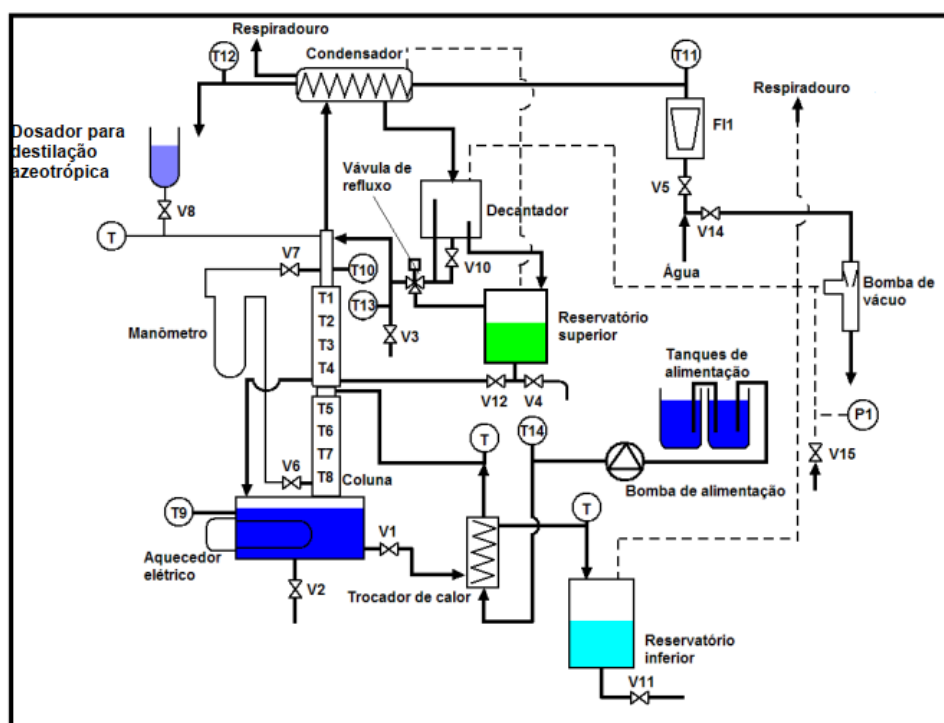


Figura 12 Esquemático de uma coluna de destilação com seus componentes básicos  
Fonte: (COELHO, 2017)

Ao se distanciar da entrada de vapor na seção de estripagem os pratos mais altos tendem a ter uma temperatura menor (mais fria) e a mistura torna a condensar fazendo um efeito cascata nos pratos.

Quando o vapor (substância A) chega ao topo da coluna ela acaba arrastando massa da substância B também, por isso existe o processo a seguir.

Ao atingir o topo, a substância A entra em um condensador o qual é alimentado por água fria através de uma válvula (V5). A função desse condensador é de condensar o

vapor que sobe pela coluna fazendo com que o material escoe para um decantador. O rotâmetro *FII* informa a vazão que passa pelo condensador. No decantador, o material segue para um reservatório (reservatório superior). Que através da válvula (*V4*) recolhe o produto de topo (produto final com a pureza desejada), mas caso a pureza ainda não seja atingida há a necessidade de voltar com esta substância para a coluna para conseguir uma pureza maior. Ela volta através da válvula *VI2*, porque uma vez o ciclo realizado pode ocorrer do vapor carregar impurezas, por isso, ele volta e realiza o processo novamente até atingir o grau de pureza desejável ou até o sistema estabilizar.

Voltando ao decantador, existe uma válvula (*VI0*) que em conjunto com a válvula de refluxo autoriza o condensado no decantador retornar a coluna de destilação (refluxo), assim este refluxo é injetado no topo da coluna. Por meio da válvula (*V3*) podemos recolher uma amostra do material.

Na seção de estripagem, quando acontece a alimentação, o líquido tende a escoar de prato em prato até atingir o fundo da coluna e quando injetado a mistura que vem do refeedor o componente do líquido mais volátil tende a volatilizar e ir em direção ao topo. O restante do líquido que não se volatiliza fica no fundo ao qual chamamos de produto de fundo. Este produto (substância B com a substância A em menor quantidade) entra no refeedor através da válvula *VI* para ser vaporizado e depois volta para a coluna. Este vapor tende a subir e ir em direção ao topo, isso é feito para ter certeza de que no produto de fundo só tenha a substância B da mistura, ao qual normalmente é classificado como resíduo. Parte do líquido que o refeedor não consegue vaporizar é retirado através do reservatório inferior e vai para fora do sistema.




Figura 13 Desenho esquemático dentro da coluna de destilação  
Fonte: (TERRON, 2000)

## 4 – Metodologia

### 4.1 - Modelo da Coluna de Destilação

O Desenvolvimento de um modelo matemático para a coluna de destilação simplifica o entendimento. O modelo desenvolvido tem que ser o mais próximo possível de uma coluna real, para que os dados obtidos possam transmitir uma credibilidade maior. Skogestad e Postlethwaite (2007) propuseram um modelo de coluna que eles chamam de coluna “A” na qual conseguem simular uma coluna de destilação usando suposições de mistura binária, pressão constante, volatilidade relativa constante, equilíbrio em todos os estágios, condensador total, fluxos molares constantes, sem retenção de vapor, dinâmica líquida linearizada, mas o efeito do fluxo de vapor ( efeito “K2”) está incluso. Essas suposições podem parecer restritivas, mas captam os principais efeitos importantes para a dinâmica e o controle. A coluna tem 41 estágios teóricos com a alimentação sendo feita no estágio 21 e separa uma mistura binária com volatilidade relativa de 1,5 em produtos de 99% de pureza de topo. Este modelo inclui um modelo não-linear MIMU “open-loop” (não controlada).

Na primeira parte desse trabalho, estuda-se o caso do funcionamento de uma torre de destilação de uma mistura genérica baseada em duas substâncias. Na segunda parte do trabalho, de caráter mais acadêmico, estuda-se a complexidade do problema e a solução aplicada a redes neurais como uma solução rápida, confiável e barata de ser implementada no controle de processos químicos não-lineares.

Na Figura 14 está o modelo no Simulink da coluna de destilação.

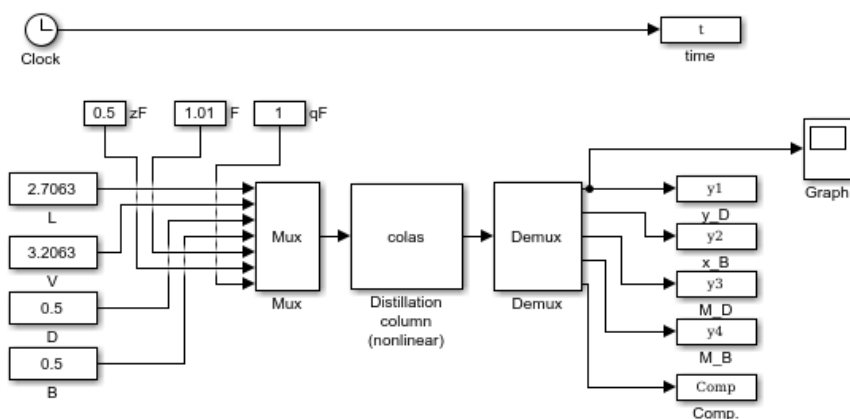


Figura 14 - Modelo Skogestad Coluna – LV

Como visto na figura existem 7 entradas sendo elas.

$L = \text{vazão de refluxo} - 2,706 \text{ kmol/min}$

$V = \text{vazão do refeedor} - 3,206 \text{ kmol/min}$

$D = \text{vazão de topo ( produto final)} - 0,5 \text{ kmol/min}$

$B = \text{vazão de fundo ( produto de fundo)} - 0,5 \text{ kmol/min}$

E 3 distúrbios:

$zF = \text{composição da alimentação} - 0,5 \text{ mol}$

$F = \text{taxa de alimentação} - 1 \text{ kmol/min}$

$qF = \text{fração líquida da alimentação} - 1 \text{ (líquido saturado)}$

Também possui 5 saídas

$y(1) = \text{composição de topo}$

$y(2) = \text{composição de fundo}$

$y(3) = \text{taxa do condensador}$

$y(4) = \text{taxa do refeedor}$

$y(5) = \text{composição da bandeja de topo e fundo}$

Os valores escritos na Tabela 1 são valores iniciais de cada variável (condições iniciais).

Tabela 1 - Valores das entradas na coluna

**Valores iniciais das entradas (Kmol/min)**

<b>LT = 2,70629</b>	<i>vazão de refluxo</i>
<b>VB = 3,20629</b>	<i>vazão do refeedor</i>
<b>D = 0,5</b>	<i>vazão de topo</i>
<b>B = 0,5</b>	<i>vazão de fundo</i>
<b>F = 1,0</b>	<i>composição da alimentação</i>
<b>zF = 0,5</b>	<i>taxa de alimentação</i>
<b>qF = 1,0</b>	<i>fração líquida da alimentação</i>

## 4.2 – Treinamento da Rede Neural

Após a validação do modelo de Skogestad, foi iniciado o treinamento da rede neural utilizando como variável de controle a vazão do refeedor (V) e a variável de saída foi a composição de topo (y1). No treinamento da rede neural foi utilizado uma configuração com 100 neurônios na camada escondida, função de ativação sigmoide e função linear para a saída.

## 4.3 – Controle usando rede neural

Feito o treinamento da rede neural, iniciou-se o controle. Por meio de um controlador PI a rede neural foi utilizada para prever o estado futuro da saída.

## 5 – Resultados e Discussões

Foram retiradas as entradas L, V, D, B e introduzidas sinais randômicos gerando várias entradas com valores diferentes para poder fazer a coleta das saídas, descrito na Figura 15. Assim tem-se dados para usar no treinamento da rede neural.

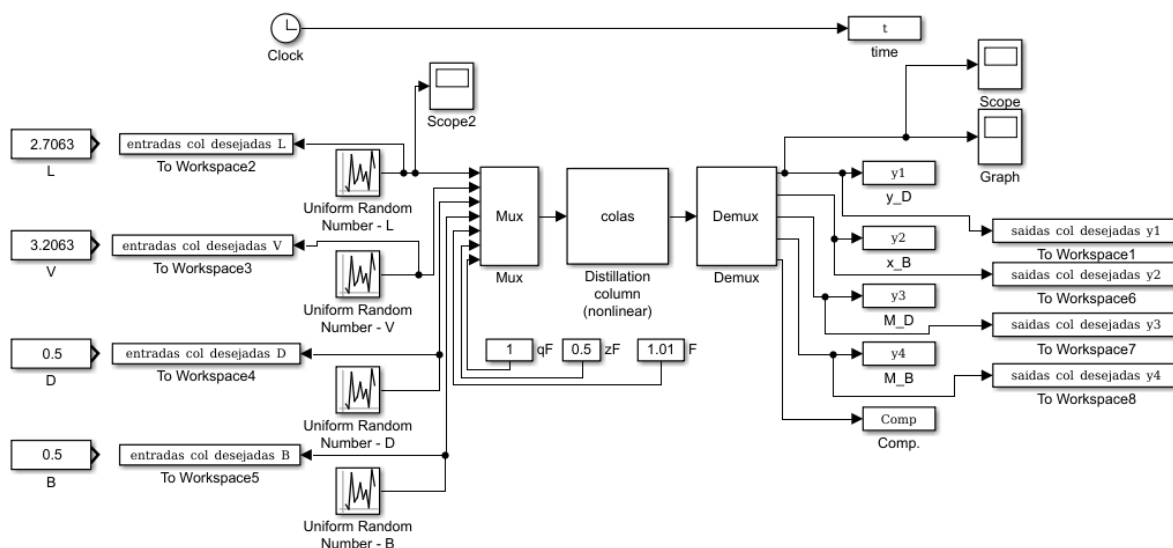


Figura 15 - Sinais randômicos inseridos

Foi simulado a coluna por 3600 minutos pegando pontos nas entradas e saídas com intervalo de 2 minutos. Gerando, portanto, 1800 pontos. Feita a simulação foi gerado matrizes de entrada e saídas das respectivas entradas randômicas e saídas. A partir dessas matrizes foi plotado os gráficos que podem ser vistos no Apêndice A.

O próximo passo foi treinar uma rede neural baseada nas 4 entradas: L, V, D, B e na saída Y1 e Y2. Estas 4 matrizes de entradas foram unificadas em uma única matriz chamada “ENTRADA\_REDE”. Na Figura 16 verifica-se o desenho dos neurônios da rede neural artificial.






Figura 16 - Definição RNA

Dentre as simulações realizadas da rede neural, a que apresentou o melhor desempenho, baixo tempo de treinamento e convergência do gradiente foi com 100 neurônios na camada oculta. Foi utilizado a função sigmoide para camada oculta por melhor se adaptar e apresentar melhores resultados em relação aos outros tipos de funções de ativação. Quatro delays foram inseridos.




Figura 17 - Resultado Treinamento

Na Figura 17 pode ser visto que em apenas 10 interações com um tempo total de 20 segundos, a rede foi treinada com sucesso, além disso a convergência do gradiente foi satisfeita, por isso o treinamento foi finalizado.




Figura 18 - Erro da RNA

Na figura 18 a linha laranja de erro zero ficou próxima da maioria dos treinamentos e validações, como vemos no eixo x, o erro está perto de  $4,6^{-05}$ , portanto, muito baixo. Na Figura 19 verificou-se que a partir da oitava iteração o erro quadrático atingiu um valor constante que pode ser verificado pela linha verde do gráfico, mesmo assim o Matlab ainda fez iterações e verificou que o erro continuava constante, podendo finalizar o treinamento.




Figura 19 - Treinamento RNA




Figura 20 - Resposta da Saída

Na figura 20, foi plotada a saída da coluna a determinadas entradas e em cima foi plotada a saída da rede neural a estas mesmas entradas. Como se vê, a rede neural adaptou-se muito.




Figura 21 - Bloco criado da RNA

Com o bloco criado da rede neural, adicionou-se as entradas "In" (é a matriz ENTRADA\_REDE atrasada em 4 minutos) e "Out" (é a matriz da saída Yi atrasada 4 minutos também, visto na Figura 21. Foi adotado o tempo de atraso de 4 minutos pelo fato de ser uma coluna dinâmica.




Figura 22 - RNA prevendo saída

Como pode-se ver na Figura 25 a rede neural conseguiu prever as saídas fornecendo os valores da entrada. Pôde-se verificar que o erro é mínimo, configurando assim um bom treinamento.

### 5.1 - Controle PI

Utilizando um controlador PI para poder garantir a saída de topo desejada, controlando a vazão do refeedor, foi esquematizado no Simulink como mostra a Figura 23.

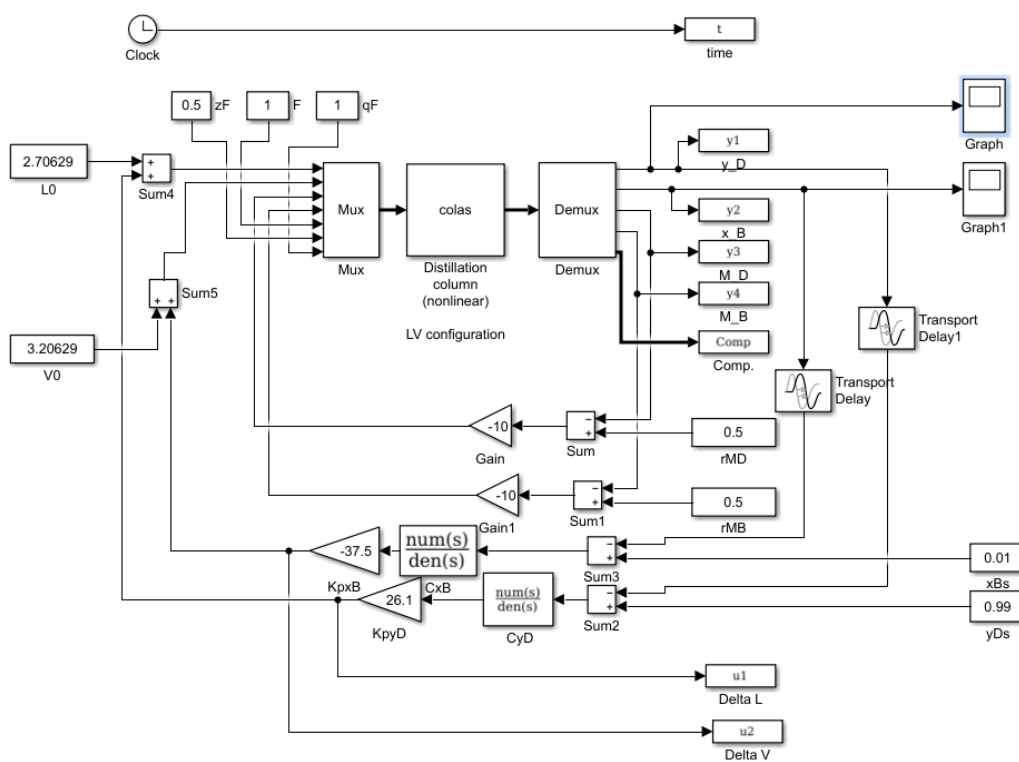


Figura 23 - Controle PI

Foi aplicado uma entrada de vazão de refluxo de  $2,706 \text{ kmol/min}$  e uma vazão do refeedor de  $3,206 \text{ kmol/min}$  simulando um comando e a saída deverá apresentar a pureza desejada. Ajustando os ganhos do controlador PI podemos chegar aos valores de pureza desejada. Foi adicionado um “*Transport Delay*” para poder garantir que a realimentação não será instantânea porque a coluna possui um atraso intrínseco ao processo. Foi adicionado 1 minuto de atraso. O ganho de um controlador PI na forma de função de transferência é descrito na equação 6.1.1.

$$u(t) = Kp[e(t) + \frac{1}{T_i} \int_0^t e(\tau) d\tau] \quad \text{Eq.6.1.1}$$

$$C(s) = Kp \left[ 1 + \frac{1}{sT_i} \right] \quad \text{Eq.6.1.2}$$

Onde para a saída y1, os ganhos são:

$$Kp = -37,5 \quad \text{Eq.6.1.3}$$

$$Ti = 3,31 \quad \text{Eq.6.1.4}$$

Para a saída y2,

$$Kp = 26,1 \quad \text{Eq.6.1.5}$$

$$Ti = 3,76 \quad \text{Eq.6.1.6}$$

Com o ajuste desses ganhos podemos tirar um gráfico da saída em relação a entrada. Foi feita uma simulação por 200 minutos. Apresentado na Figura 24.




Figura 24 - Saída y1 com controlador PI

Como pode-se verificar a saída apresentou um leve overshooting no início e depois uma oscilação flutuante em torno dos 99% de pureza e a acomodação em torno dos 80 minutos.

Foi introduzido a rede neural treinada para poder zerar este erro, como uma rede preditiva com ganho derivativo.

## 5.2 – Rede Neural Preditiva

Uma rede neural preditiva irá prever o estado futuro da saída e assim poder corrigi-lo para minimiza-lo o máximo possível o erro.

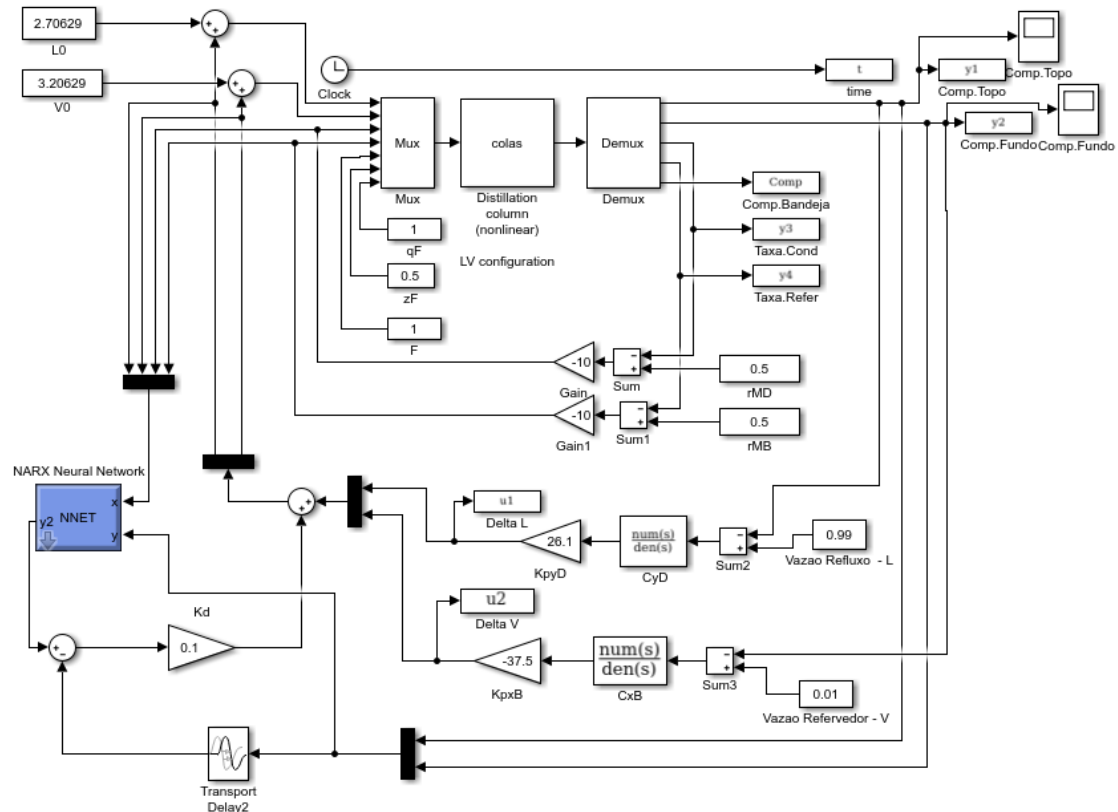


Figura 25 - Controle neural

Na Figura 28 tem um esquemático no Simulink de como ficou a coluna de destilação com a rede neural preditiva aplicada, destacada em azul.

Através da Figura 26 pode-se ver resposta da rede. Foi simulado um tempo de 200 minutos.

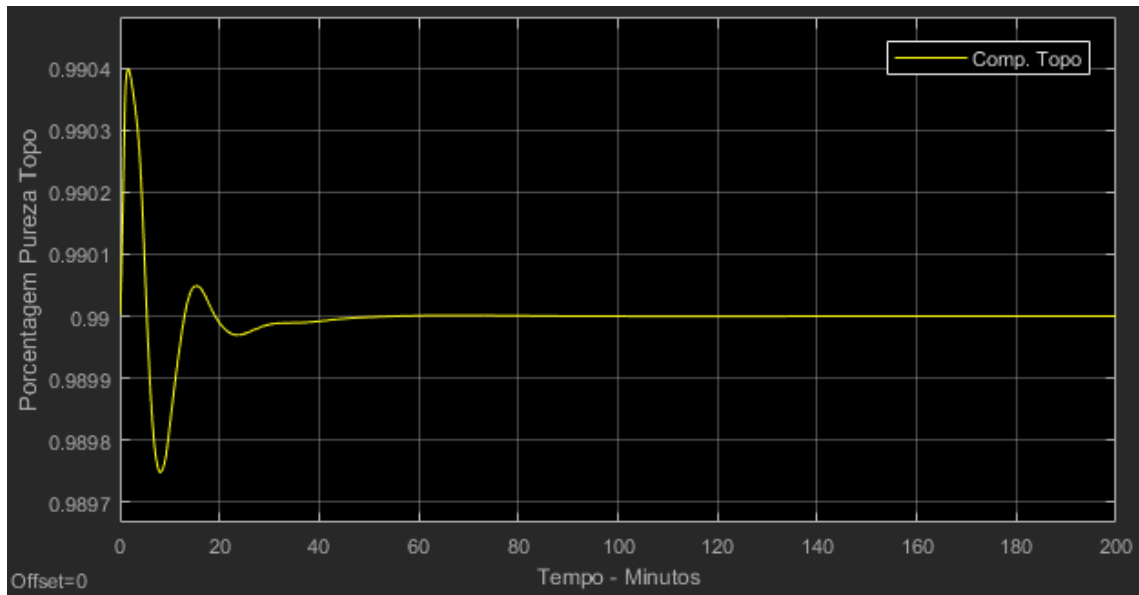


Figura 26 - Gráfico controle Rede Neural

Com a introdução da rede neural preditiva pôde-se verificar na Figura 26 que deixou o controle mais rápido diminuindo o tempo de acomodação para algo em torno de 60 minutos e também houve diminuição do overshooting.

Foram plotadas as 2 saídas em um único gráfico e foi constatado o resultado na Figura 27.




Figura 27 - Gráfico comparativo - Y1



Utilizando a Figura 27 como apoio calculou-se a diferença entre o ponto máximo da saída azul (saída só com PI) e o ponto máximo da saída amarela (saída com rede neural) assim como a média, mediana, moda, desvio padrão e o alcance. Estes resultados encontram-se na Tabela 2.

Tabela 2 – Composição de Topo só PI

	<b>Eixo x - Tempo</b>	<b>Eixo y - %</b>
<b>Mínimo</b>	0	0,9898
<b>Máximo</b>	200	0,9915
<b>Média</b>	80,77	0,9901
<b>Mediana</b>	75,73	0,99
<b>Moda</b>	0	0,9898
<b>Desvio padrão</b>	58,01	0,0003701
<b>Alcance</b>	200	0,001727

Calculou-se também a estatística descritiva da composição de topo com rede neural artificial, apresentada na Tabela 3.

Tabela 3– Composição de Topo com rede neural

	<b>Eixo x - Tempo</b>	<b>Eixo y - %</b>
<b>Mínimo</b>	0	0,9897
<b>Máximo</b>	200	0,9904
<b>Média</b>	80,77	0,99
<b>Mediana</b>	75,73	0,99
<b>Moda</b>	0	0,9898
<b>Desvio padrão</b>	58,01	0,0001006
<b>Alcance</b>	200	0,000651

Como verificado o ponto máximo da saída só com o PI apresentou um valor de 0,9915 enquanto o da saída com a rede neural apresentou um valor de 0,9904. Portanto o overshooting da coluna só com o PI foi maior em 0,11% em relação a coluna com a Rede Neural Preditiva. O tempo de acomodação foi 33% maior utilizando só PI, portanto, a introdução de uma rede neural preditiva provou ser uma ótima alternativa para o controle de uma coluna de destilação na configuração LV. No anexo C podemos ver a mesma análise só que referente a saída Y2 – Composição de fundo.

## Conclusão

A implementação da rede neural preditiva em um sistema com controle PI melhorou significativamente o desempenho do controlador. Ficou claro que novas técnicas de controle na engenharia química são bem-vindas e se forem bem aplicadas rendem muitos benefícios. Pôde-se observar um tempo de acomodação 33% menor e um overshooting 0,11% menor para o controle da saída Y1 – composição de topo, na configuração LV de uma coluna de destilação. Portanto, pode-se concluir que além da vantagem do controle utilizando uma rede neural agregada a um controlador PI, a área química e a tecnologia estão desenvolvendo-se a passos largos e há a necessidade das técnicas de controle serem atualizadas para as empresas poderem continuar competitivas em escala global. Olhando pelo outro lado, conclui-se que o controle por rede neural, comparado aos controladores PID convencionais, tem muito potencial para se instalar e abrir espaço na indústria química. Se bem aplicada, a rede neural consegue se sair muito bem em sistemas dinâmicos complexos, como as colunas de destilação que foram o principal objeto deste trabalho.

## Bibliografia

- AGUIAR, G. F. **Utilização de redes neurais artificiais para detecção de padrões de vazamentos em dutos. Dissertação ( Mestrado Engenharia)**. São Carlos: Escola de Engenharia de São Carlos da Universidade de São Paulo, 2010.
- BLANCHARD, S. M. Anatomy and Physiology. **Introduction to Biomedical Engineering**, San Diego, 2000. 29-78,1062p.
- BORCHARDT, F. L. Neural network computing and natural language processing. **Calico journal**, v. 5, n. 4, p. 63-75, 1988.
- CARVALHO, A. P. D. L. F. D. conteúdo.icmc.usp.br. **USP**, 2009. Disponível em: <<http://conteudo.icmc.usp.br/pessoas/andre/research/neural/>>. Acesso em: 04 jul. 2018.
- COELHO, P. engquimicasantosp.com.br. **Eng.quimica Santos**, 2017. Disponível em: <<https://www.engquimicasantosp.com.br/2017/06/destilacao-fracionada-laboratorio-industria.html>>. Acesso em: 13 jul. 2018.
- CYBENKO, G. Approximations by superpositions of sigmoidal function mathematics of control, signals and systems, 1989. 303-314.
- FOUST, A. S.; CLUMP, C. W. **Princípios das Operações Unitárias**. 2. ed. Rio de Janeiro: LTC, 1982.
- GUYON, I. Neural networks and application tutorial. **Physics Reports**. v.17 n3, p.215-259.
- HOPFIELD, J. J. Neural networks and physical systems with emergent collective computational abilities. **Proceedings of the National Academy of Sciences of the USA**, v. 79, p. 2555-2558, 1982.
- JUNIOR, N. A. **Aplicações de redes neurais utilizando o software matlab**. [S.l.]: Centro universitário Eurípedes de Marília - UNIVEM, 2005.
- MADEIRA, D. embarcados.com.br. **Embarcados**, 2016. Disponível em: <<https://www.embarcados.com.br/amostragem-em-controle-digital>>. Acesso em: 22 ago. 2018.
- MCCABE, W. L.; SMITH, J. C.; HARRIOTT, P. **Unit Operations of Chemical**. 5. ed. New York: McGraw-Hill, 1993.
- MCCULLOCH, W. S.; PITTS, W. H. A logical calculus of the ideas immanent in nervous activity. **Bulletin of mathematical biophysics**, 1943. v.5,p.115-133.
- PALMIERE, S. E. embarcados.com.br. **Embarcados**, 2016. Disponível em: <<https://www.embarcados.com.br/redes-neurais-artificiais/>>. Acesso em: 01 set. 2018.
- PALMIERE, S. E. embarcados.com.br. **Embarcados**, 2016. Disponível em: <<https://www.embarcados.com.br/rede-perceptron-de-uma-unica-camada/>>. Acesso em: 12 jun. 2018.
- PORTELA, O. P. **Apresentação de trabalhos acadêmicos de acordo com as normas de documentação da ABNT: informações básicas**. Uberaba, Minas Gerais: [s.n.], 2015.
- TEIXEIRA, E. P. **Controle de sistemas não lineares por meio de redes neurais artificiais**. [S.l.]: Tese de Doutorado, Unicamp, 1991.

TERRON, L. R. <http://sites.poli.usp.br>. **Destilação**, 2000. Disponível em:  
<[http://sites.poli.usp.br/p/luiz.terron/destilacao/\\_private/copyright.htm](http://sites.poli.usp.br/p/luiz.terron/destilacao/_private/copyright.htm)>. Acesso em: 13 jul.  
2018.

Z.KISTER, H. **Distillation Design McGraw**. 1. ed. [S.l.]: Hill Education, 1992.

## Anexo(s)

### Anexo A – Aspecto do programa

O Matlab é um software com inúmeras ferramentas computacionais de cálculos numéricos e gráficas. Foi desenvolvido com o princípio de facilitar o desenvolvimento de projetos porque a maioria das ferramentas estão disponíveis em toolbox (caixas de ferramentas). Com isso sua implementação fica mais rápida e confiável.

Por se tratar de um software com poder computacional, a implementação de uma rede neural fica definida por uma GUI (interface gráfica do usuário) com várias opções de redes neurais como, tipos de neurônios, algoritmos de aprendizagem, múltiplas camadas. Para esta implementação é necessário um conhecimento prévio sobre esta toolbox em específico.

São funções responsáveis para criar a arquitetura de uma rede neural, ligando e interligando todos os neurônios e simulando as entradas, saídas e valores de ativação.

*nnstart*: Abre o toolbox de RNA.

Sintaxe: *nnstart*

## Anexo B – Gráficos das entradas e saídas da coluna de destilação

As Figuras seguintes são os gráficos plotados referente as entradas randômicas e das saídas da coluna de destilação. Na Figura 28, no eixo y temo as unidades em kmol/min, no eixo x tem o tempo em minutos e a linha amarela representa a vazão de refluxo L.




Figura 28 - Sinal randômico aplicado na entrada - Vazão Refluxo

Na Figura 29, o eixo y tem as unidades em kmol/min, no eixo x tem o tempo em minutos e a linha amarela representa a vazão do refervedor V.




Figura 29 - Sinal randômico aplicado na entrada - Vazão Refervedor

Na Figura 30, o eixo y tem as unidades em kmol/min, no eixo x tem o tempo em minutos e a linha amarela representa a vazão de topo D.

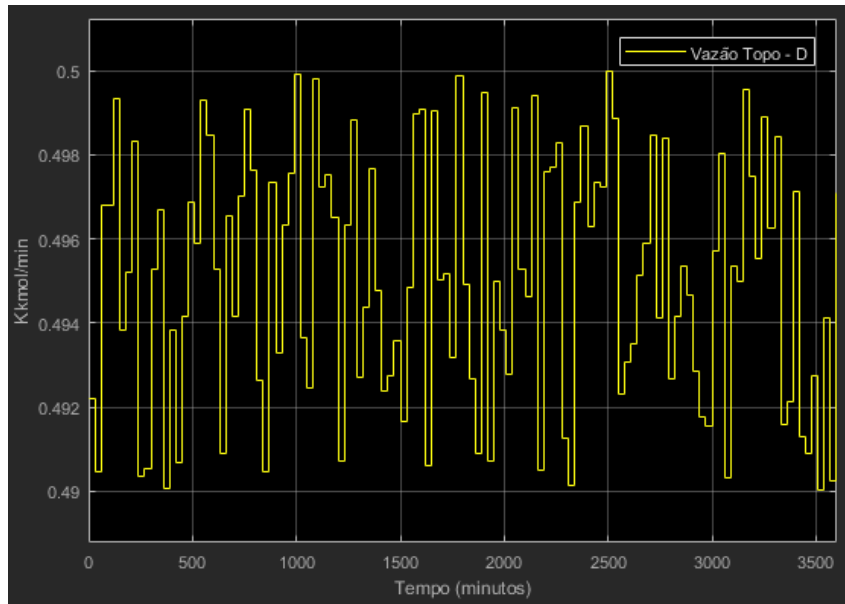


Figura 30 - Sinal randômico aplicado na entrada - Vazão Topo

Na Figura 31, o eixo y tem as unidades em kmol/min, no eixo x tem o tempo em minutos e a linha amarela representa a vazão de fundo B.




Figura 31 - Sinal randômico aplicado na entrada - Vazão Fundo

Na Figura 32, o eixo y tem a composição, no eixo x tem o tempo em minutos e a linha amarela representa a composição de topo y1.

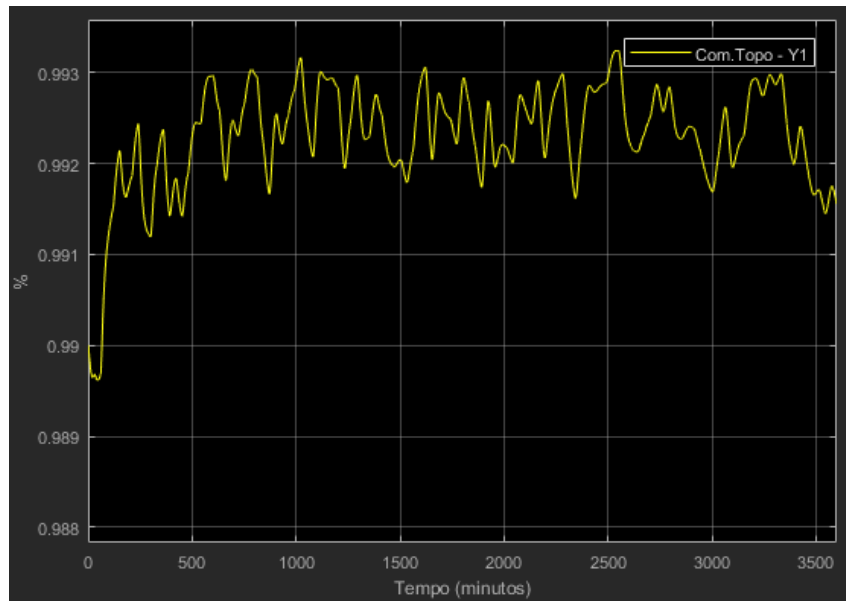


Figura 32 - Composição topo - Y1

Na Figura 33, o eixo y tem a composição, no eixo x tem o tempo em minutos e a linha amarela representa a composição de topo y2.




Figura 33 - Composição fundo - Y2

Na Figura 34, o eixo y tem a composição, no eixo x tem o tempo em minutos e a linha amarela representa a taxa do condensador y3.



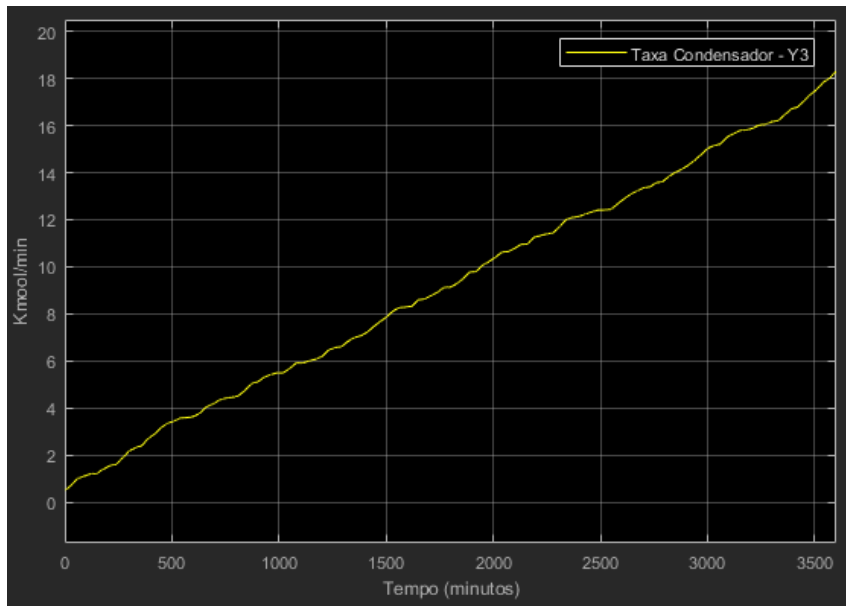


Figura 34 - Taxa Condensador - Y3

Na Figura 35, o eixo y tem a composição, no eixo x tem o tempo em minutos e a linha amarela representa a taxa do refeedador y4.




Figura 35 - Taxa refeedador - Y4

## Anexo C – Análise da Saída de Composição de Fundo




Figura 36 - Composição de fundo com Rede Neural




Figura 37 – Composição de fundo só com PI




Figura 38 - Comparação Rede e PI

Nas Tabelas 4 e 5 pode-se visualizar melhor a diferença entre as tabelas da composição de fundo com aplicação da rede neural preditiva e com o controlador PI sozinho.

Tabela 4 – Composição Fundo com rede neural

	<b>Eixo x - Tempo</b>	<b>Eixo y - %</b>
<b>Mínimo</b>	0	0,009574
<b>Máximo</b>	200	0,0107
<b>Média</b>	80,77	0,01001
<b>Mediana</b>	75,73	0,01
<b>Moda</b>	0	0,009574
<b>Desvio padrão</b>	58,1	0,000125
<b>Alcance</b>	200	0,001131

Tabela 5– Composição Fundo só PI

	<b>Eixo x - Tempo</b>	<b>Eixo y - %</b>
<b>Mínimo</b>	0	0,008937
<b>Máximo</b>	200	0,0126
<b>Média</b>	80,77	0,01005
<b>Mediana</b>	75,73	0,01
<b>Moda</b>	0	0,01
<b>Desvio padrão</b>	58,1	0,0004523
<b>Alcance</b>	200	0,003659

Como verificado o ponto máximo da saída só com o PI apresentou um valor de 0,0126 enquanto o da saída com a Rede Neural apresentou um valor de 0,0107, como visto na Figura 38, portanto, o overshooting da coluna só com o PI foi maior em 17,75% em relação a coluna com a rede neural preditiva e o tempo de acomodação foi o mesmo.