



**CENTRO FEDERAL DE EDUCAÇÃO TECNOLÓGICA DE MINAS GERAIS
UNIDADE ARAXÁ**

ESTEFANA ALVES RIBEIRO

**CONTROLE DE TEMPERATURA COM UTILIZAÇÃO DE
CONTROLADOR NEURAL**

ARAXÁ/MG

2016

ESTEFANA ALVES RIBEIRO

**CONTROLE DE TEMPERATURA COM UTILIZAÇÃO DE
CONTROLADOR NEURAL**

Trabalho de Conclusão de Curso apresentado ao Curso de Engenharia de Automação Industrial, do Centro Federal de Educação Tecnológica de Minas Gerais - CEFET/MG, como requisito parcial para obtenção do grau de Bacharel em Engenharia de Automação Industrial.

Orientador: Prof. Me. Frederico Duarte Fagundes

ARAXÁ/MG

2016

ATA DE APROVAÇÃO

ESTEFANA ALVES RIBEIRO

CONTROLE DE TEMPERATURA COM UTILIZAÇÃO DE CONTROLADOR NEURAL

Trabalho de Conclusão de Curso apresentado ao Curso de Engenharia de Automação Industrial, do Centro Federal de Educação Tecnológica de Minas Gerais - CEFET/MG, como requisito parcial para obtenção do grau de Bacharel em Engenharia de Automação Industrial.

Araxá, 07 de julho de 2016.

Presidente e Orientador: Prof. Me. Frederico Duarte Fagundes

Centro Federal de Educação Tecnológica de Minas Gerais – CEFET/MG – Unidade
Araxá

Membro Titular: Prof. Me. Herbert Radispiel Filho

Centro Federal de Educação Tecnológica de Minas Gerais – CEFET/MG – Unidade
Araxá

Membro Titular: Prof. Me. Leandro Resende Mattioli

Centro Federal de Educação Tecnológica de Minas Gerais – CEFET/MG – Unidade
Araxá

Membro Titular: Prof. Dr. Wanderley Alves Parreira

Centro Federal de Educação Tecnológica de Minas Gerais – CEFET/MG – Unidade
Araxá

DEDICO ESTE TRABALHO

À minha família.

Às pessoas que acreditaram em mim.

*Às pessoas que não acreditaram, me dando, assim,
a vontade de superar minhas próprias barreiras.*

AGRADECIMENTOS

Agradeço à minha família pelo amor, pelo apoio e pelo sustento necessário durante toda essa etapa. Sem esse apoio, teria sido impossível chegar até aqui. Em especial, agradeço à minha querida mãe, Edileusa; essa vitória é nossa.

Agradeço ao meu orientador, Frederico Duarte Fagundes, pelo acompanhamento e pela oportunidade de aprender tanto. Agradeço ainda pela paciência e pela dedicação ao me orientar nesse verdadeiro desafio. Possuía pouco conhecimento sobre o assunto tratado. Pesquisei, estudei e aprendi. Obrigada por ter acreditado que eu seria capaz.

Agradeço ao Prof. Henrique José da Costa Avelar, que (in)diretamente contribuiu muito para este trabalho, me auxiliando sempre que necessitava, tirando dúvidas, levantando questionamentos e, assim, me fazendo pensar e melhorar sempre o que estava fazendo.

Agradeço à Érica Daniela de Araújo que, desde o início, não mediu esforços pela qualidade deste trabalho.

Aos meus amigos de caminhada que, direta ou indiretamente contribuíram não só para este trabalho, mas também para minha formação e engrandecimento pessoal e acadêmico, em especial: Wagner Roger, Maicon Leite e Tia Íris.

Ao meu amado, Leonardo, pelo carinho, pelo amor e pela paciência. Obrigada por todos os dias ter me incentivado, apoiado e acreditado. Você faz parte desta conquista.

[...]And she's buying a stairway to heaven.

Jimmy Page – Led Zeppelin

RESUMO

Com este trabalho objetiva-se criar o controle de uma planta de temperatura didática, localizada no Laboratório de Automação e Controle, do Centro Federal de Educação Tecnológica de Minas Gerais – CEFET-MG – Unidade Araxá-MG, a partir de sua identificação via Rede Neural Artificial. Em outras palavras, através do modelo matemático da planta de temperatura, obtido por algoritmos de redes neurais, será desenvolvido o Controlador Neural. Este estudo parte da seguinte hipótese: se, a partir da identificação do sistema via Rede Neural Artificial, for atingido um valor de *setpoint* pré-determinado na planta de temperatura, então pode-se utilizar os valores obtidos como parâmetros de controle. São demonstradas, nos resultados deste trabalho, análises gráficas do desempenho do Controlador desenvolvido e Comparativos com Controlador PID.

Palavras-chave: Sistema de Controle. Controle de Temperatura. Rede Neural Artificial. Identificação de Sistemas. Controlador Neural.

ABSTRACT

This work has the objective to creating the control of a didactic temperature plant, located in the Automation and Control Laboratory at the Federal Center of Technological Education of Minas Gerais - CEFET-MG - Araxá-MG, from the identification via Artificial Neural Network. Through mathematical model of the temperature plant, obtained by neural network algorithms, a neural controller will be developed. This study supports the following hypothesis: if, from the identification via Artificial Neural Network system, a predetermined set point value is reached in the temperature plant, then the values as control parameters can be used. It is demonstrated in the results of this work, performance graphical analysis from the developed Controller and Comparative with PID controller.

Keywords: Control System. Control Temperature. Artificial Neural Network. System Identification . Neural Controller.

LISTA DE ILUSTRAÇÕES

Figura 1: Sistema de Controle.....	14
Figura 2: Sistema de Malha Aberta.	15
Figura 3: Sistemas de Malha fechada.....	15
Figura 4: Neurônio Artificial.....	19
Figura 5: Função Sigmóide.....	20
Figura 6: Função Hiperbólica.....	20
Figura 7: Função Linear.....	21
Figura 8: Função Degrau.....	21
Figura 9: RNA de uma camada.....	23
Figura 10: RNA de múltiplas camadas.....	23
Figura 11: Controle Direto.....	25
Figura 12: Controle Inverso.....	26
Figura 13: Diagrama de controle baseado em modelo de referência.....	26
Figura 14: Diagrama de controle baseado em modelo interno.....	27
Figura 15: Diagrama de controle baseado em RNA recursiva.....	27
Figura 16: Diagrama de controle ótimo baseado em RNA.....	28
Figura 17: Diagrama de controle preditivo baseado em RNA.....	28
Figura 18: Visão sinóptica da planta de temperatura.....	29
Figura 19: Diagrama Controlador Neural.....	32
Figura 20: Resultado Teste 1 - Aquecimento.....	33
Figura 21: Resultado Teste 2 - Aquecimento.....	34
Figura 22: Resultado Teste 3 - Aquecimento.....	35
Figura 23: Resultado Teste 4 - Aquecimento.....	36

Figura 24: Resultado Teste 5 - Aquecimento.....	36
Figura 25: Resultado Teste 6 - Aquecimento.....	37
Figura 26: Resultado Teste 7 - Aquecimento.	38
Figura 27: Resultado Teste 8 - Aquecimento.....	38
Figura 28: Resultado Teste 9 - Resfriamento.	39
Figura 29: Resultado 1 Controle PID - Aquecimento.....	40
Figura 30: Resultado 2 Controle PID – Aquecimento.....	41
Figura 31: Resultado 3 Controle PID – Resfriamento.	42
Gráfico 1: Comparativo entre Controladores - Aquecimento.....	43
Gráfico 2: Comparativo entre Controladores – Aquecimento.....	44
Gráfico 3: Comparativo entre Controladores – Resfriamento.	45

SUMÁRIO

1	INTRODUÇÃO	11
2	REFERENCIAL TEÓRICO	14
2.1	SISTEMAS DE CONTROLE	14
2.1.1	Sistemas de Malha Aberta.....	14
2.1.2	Sistemas de Malha Fechada.....	15
2.2	IDENTIFICAÇÃO DE SISTEMAS	16
2.3	SISTEMAS INTELIGENTES	17
2.4	REDE NEURAL ARTIFICIAL	18
2.4.1	Neurônio Artificial.....	18
2.4.2	Arquiteturas de rede	22
2.4.3	Tipos de aprendizagem	24
2.5	CONTROLADORES COM RNA	25
2.6	PLANTA DIDÁTICA DE TEMPERATURA	28
3	MATERIAIS E MÉTODOS	31
4	ANÁLISE DOS DADOS	33
5	RESULTADOS	43
6	CONCLUSÕES	46
	REFERÊNCIAS	47

1 INTRODUÇÃO

No avanço da ciência e da engenharia, o controle automático tem exercido papel muito importante, tornando-se parte fundamental de processos industriais modernos e de produção. Nesse cenário, plantas de controle didáticas são muito utilizadas em projetos com a finalidade de desenvolver e aplicar métodos de controle que propiciem resultados cada vez mais precisos, auxiliando, assim, no desenvolvimento de novas tecnologias. Além disso, com o intuito de preparar os técnicos e os engenheiros da área, são utilizadas plantas didáticas que permitem a execução de processos de controle e de supervisão em um sistema compacto e, ao mesmo tempo, fiel à realidade da Automação Industrial.

Para o controle de uma planta de temperatura, por exemplo, o líquido é levado, com a ajuda de uma bomba, de um tanque coletor a um pequeno tanque, no qual acontece seu aquecimento. A partir de uma temperatura pré-estabelecida como desejável (*setpoint*), é necessário ajustar os parâmetros de controle para estabilizar o sistema, uma vez que esse sofre interferências. Neste trabalho foi utilizada uma planta de temperatura, localizada no Laboratório de Automação e Controle, do Centro Federal de Educação Tecnológica de Minas Gerais – CEFET-MG – Unidade Araxá-MG, a fim de realizar o controle partindo da Identificação do Sistema via Redes Neurais Artificiais (RNAs) e constituindo, assim, um Controlador Neural.

Esse interesse se justifica, uma vez que, cada vez mais, os sistemas modernos, com muitas entradas e saídas, se tornam mais e mais complexos. Logo, a descrição de um sistema de controle moderno requer um grande número de equações. Sendo assim, a teoria clássica de controle, que trata somente de sistemas com uma entrada e uma saída, tornou-se insuficiente para sistemas com múltiplas entradas e saídas (OGATA, 2003). Em vista desse contexto, através de Redes Neurais Artificiais (RNAs), é possível fazer o modelamento de um sistema, utilizando múltiplas variáveis de entrada e variáveis de saída, de modo que a rede aprenda o comportamento do sistema e seja capaz de reproduzi-lo.

Uma rede neural artificial é composta por vários processadores simples ou unidades de processamento. Tais unidades têm conexões através de canais de comunicação que estão associados a determinado peso (valores numéricos). Sendo assim, o comportamento de uma Rede Neural Artificial vem das interações entre as

unidades de processamento da rede, uma vez que estas fazem operações apenas sobre seus dados locais, que são entradas recebidas pelas suas conexões. Segundo Prottes (2009), uma RNA pode ser utilizada em sistema de controle como modelo de processo, fornecendo a predição de uma saída de um processo em um determinado instante de tempo. Dessa forma, é possível tomar decisões com antecedência, como, por exemplo, correção de erros, alterações no modelo do processo etc.

Atualmente, vários métodos de controle estão sendo desenvolvidos, pois, em processos mais complexos, apenas controladores clássicos não garantem uma boa eficácia. Existem vários tipos de controladores modernos, sendo esses divididos em 3 grandes grupos: Controle Robusto, Controle Adaptativo e o Controle Inteligente. Esse último é objeto de estudo deste trabalho.

Em vista do apresentado, este trabalho possui como objetivo geral: fazer o controle de uma planta de temperatura, a partir da identificação do sistema via RNA, ou seja, a partir do treinamento da rede e utilizar os valores obtidos para alcançar o *setpoint* pré-definido na planta. Para tanto, os seguintes objetivos específicos foram considerados, quais sejam: a) aprofundar os conhecimentos em Sistemas de Controle; b) conhecer conceitos básicos sobre Rede Neural Artificial, para a execução do trabalho; c) desenvolver o Controlador; d) realizar Controle PID; e) comparar resultados entre Controladores.

Logo, este estudo parte da seguinte hipótese de pesquisa: se, utilizando o modelo obtido a partir da identificação do sistema via Rede Neural Artificial, for atingido um valor de *setpoint* pré-determinado na planta de temperatura, então pode-se utilizar os valores obtidos na identificação como parâmetros de controle.

Além da oportunidade em aplicar os conhecimentos adquiridos em sala de aula, projetos nesta área são cada vez mais importantes, pois há exigências no mercado por novas tecnologias e investimentos na área de desenvolvimento computacional aliado à automação. Esse desenvolvimento permite melhorar processos, produtividade e, conseqüentemente, resultados. Dessa forma, este trabalho apresenta uma alternativa em precisão de processos de controle em plantas de temperatura, essa que é muito utilizada em indústrias, a partir da identificação do sistema por método computacional, estabelecendo melhores parâmetros de controle e estabilização de temperatura.

Este trabalho se estrutura textualmente da seguinte maneira: no próximo capítulo será apresentada a revisão bibliográfica que fundamenta teoricamente este

estudo; posteriormente, apresentar-se-á os Materiais e Métodos utilizados nesta pesquisa; na sequência, os resultados obtidos e; por fim, as conclusões deste trabalho.

2 REFERENCIAL TEÓRICO

2.1 SISTEMAS DE CONTROLE

Sendo o foco principal deste trabalho o controle de uma planta de temperatura, é importante partir de conceitos já previamente estabelecidos acerca desse tema, de modo a melhor precisá-los. Conforme Nise (2011, p. 6), “um sistema de controle consiste em subsistemas e processos (ou plantas) construídos com o objetivo de se obter uma saída desejada com desempenho desejado, para uma entrada específica fornecida”. Logo, esse conceito pode ser descrito simplificadaamente conforme a figura 1:




Figura 1: Sistema de Controle.

Ressalta-se que sistemas de controle sempre foram utilizados ao longo da história, sendo aperfeiçoados a partir da Revolução Industrial no século XVIII. Com o crescimento industrial, novos métodos de produção foram desenvolvidos, necessitando, assim, de controle para garantir eficiência, qualidade e segurança. Atualmente, os sistemas de controle são comandados por computadores, como, por exemplo, robôs industriais, aviação e controle de processos industriais. Conforme exposto, o bom controle minimiza possíveis erros no sistema, garantindo maior precisão e confiabilidade.

2.1.1 Sistemas de Malha Aberta

Um sistema de Malha Aberta pode ser entendido como um sistema em que o controle independe do valor de saída. Nos termos de Nise (2011, p. 7), “os sistemas de malha aberta não são capazes de corrigir perturbações e são comandados simplesmente pela entrada”. Na figura 2 ilustra-se um sistema de Malha Aberta:




Figura 2: Sistema de Malha Aberta.
Fonte: Adaptado de Nise (2011, p. 7).

Conforme a figura 2, em um sistema de Malha Aberta genérico, o transdutor converte o sinal de entrada, o controlador aciona o processo ou planta e, na saída, tem o sinal controlado, chamado também de variável controlada. Observando as perturbações na ilustração, é visto que elas são somadas ao processo, e não há compensação para tais perturbações (Cf. NISE, 2011).

2.1.2 Sistemas de Malha Fechada

Em um sistema de Malha Fechada, o controle depende do valor de saída, ou seja, esse tipo de sistema tem uma realimentação para compensar possíveis perturbações.

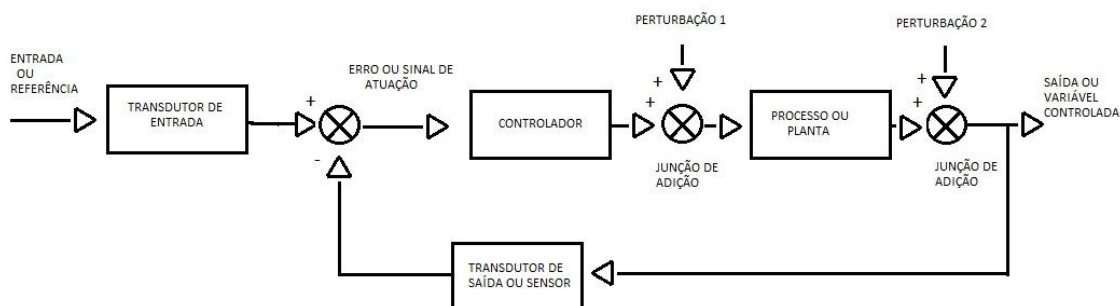


Figura 3: Sistemas de Malha fechada.
Fonte: Adaptado de Nise (2011, p. 7).

Na figura 3 é demonstrado um sistema em Malha Fechada genérico, no qual o transdutor converte o sinal de entrada, o controlador aciona a planta ou processo e, diferente do sistema de Malha Aberta, o sinal retorna ao outro transdutor, podendo ser também um sensor que efetua a leitura o valor dessa variável. Se necessário, as devidas correções são executadas, e esse sinal ou variável retorna ao controlador (NISE, 2011).

2.2 IDENTIFICAÇÃO DE SISTEMAS

De acordo com Aguirre (2007a, p. 81), “a identificação de sistemas se propõe a obter um modelo matemático que explique, pelo menos em parte e de forma aproximada, a relação de causa e efeito presente nos dados”. Ou seja, em um sistema com sinais de entrada e saída, a identificação apresenta um modelo que mostra como a excitação de um sinal de entrada resulta em um sinal de saída. Ainda segundo Aguirre (2007a, p. 81), existem etapas importantes envolvidas na identificação de sistemas, quais sejam: “testes dinâmicos e coleta de dados; escolha da representação matemática a ser usada; determinação da estrutura do modelo; estimação de parâmetros; e validação do modelo”.

Alguns conceitos são utilizados para classificar as técnicas de Modelagem, as quais podem ser: Caixa Branca, Caixa Preta e Caixa Cinza.

- Caixa Branca: nesse tipo de modelagem, a estrutura das equações dos modelos é determinada por leis físicas, químicas etc., ou seja, leis que regem o comportamento dinâmico do sistema em questão;
- Caixa Cinza: a Modelagem em caixa cinza parte de algum conhecimento prévio ou auxiliar para a construção do modelo;
- Caixa Preta: nessa modelagem, o conjunto de dados dinâmicos é a única fonte de informação para a construção do modelo.

Uma mesma estrutura de modelo pode ser utilizada tanto para a modelagem em caixa cinza quanto para a modelagem em caixa preta. A diferença estará nos parâmetros, ou seja, na interpretação física dos mesmos (AGUIRRE, 2007a).

Entre os propósitos para a construção de Modelo, destacam-se:

- Previsão: prever possíveis estados futuros de um sistema ou comportamento dinâmico;
- Análise e projeto de sistemas de controle: sintonia de controladores, síntese de algoritmos, estimativas de estado;
- Supervisão: criação e utilização de modelos para detecção de erros;
- Otimização: tomada de decisões assertivas.

Acresce-se a essa explanação os tipos de Modelos a serem considerados, quais sejam:

- Modelos Determinísticos: um sistema é determinístico se “para um dado estado inicial e uma dada entrada houver apenas uma saída possível” (AGUIRRE, 2007a, p. 60). Assim, esses sistemas trabalham com relações exatas entre as variáveis medidas, não havendo incertezas.
- Modelos Estocásticos: um sistema estocástico se refere a “sistemas submetidos a entradas de comportamento incontrollável e aleatório, conhecidas como ruído” (AGUIRRE, 2007a, p. 60). Esse tipo de modelo trabalha com incertezas e probabilidades.
- Modelos Contínuos: modelo que descreve a relação entre sinais de tempo contínuo.
- Modelos Discretos: modelo em que os sinais de interesse são obtidos em tempo discreto.

2.3 SISTEMAS INTELIGENTES

Devido à complexidade de alguns processos, controladores clássicos podem não ser tão eficazes. Uma boa opção para tais processos é a utilização de Sistemas Inteligentes, por meio dos quais se procura dotar as máquinas de inteligência. Assim, a Inteligência Artificial (IA) é uma importante ferramenta na Automação. Tanto o é que, segundo Aguirre (2007b), é possível citar vários exemplos de aplicações de Inteligência Artificial, entre os quais se destaca:

- Interfaceamento Homem-Máquina: o equipamento pode criar alertas (visual, auditivo e sonoro) sobre possíveis problemas e soluções;
- Reconhecimento de padrões: classificação e agrupamentos por padrões definidos;
- Raciocínio sobre incertezas: capacidade de trabalhar com informações incertas ou imprecisas;
- Tomada de decisões: considerar as incertezas e conciliar objetivos;
- Sistemas especialistas: utilização de vários especialistas (conhecimentos);
- Sistemas adaptativos: construção de sistemas com reações adequadas às variações do meio ambiente;
- Descoberta de conhecimento: adquirir conhecimentos a partir de observações e experiências.

Salienta-se que uma das ferramentas mais utilizadas ultimamente para facilitar o emprego de sistemas com Inteligência Artificial é a RNA (Rede Neural Artificial), sendo essa a ferramenta escolhida para o desenvolvimento deste estudo.

2.4 REDE NEURAL ARTIFICIAL

Haykin (2001, p. 28) afirma que uma Rede Neural é um processador composto por unidades de processamento simples, que têm capacidade de armazenar conhecimento experimental e torná-lo disponível para uso. Ela se assemelha ao cérebro em dois aspectos:

- Através da aprendizagem, o conhecimento é adquirido pela rede a partir de seu ambiente;
- Pesos sinápticos, ou forças de conexão entre neurônios, são utilizados para armazenar o conhecimento adquirido.

Em vista disso, a partir de um algoritmo de aprendizado, é efetuada a aprendizagem da rede neural, na qual os pesos sinápticos são atualizados durante a execução dessa, com a finalidade de se alcançar um resultado desejado (HAYKIN, 2001). Ainda segundo Haykin (2001, p. 37-38), o uso de Redes Neurais oferece propriedades úteis e capacidades, podendo, entre elas, destacar a:

- Não-linearidade: um neurônio artificial pode ser linear ou não linear;
- Adaptabilidade: as redes possuem capacidade de adaptação de seus pesos sinápticos a modificações do meio, ou seja, podem ser treinadas para uma nova condição;
- Tolerância a falhas: sob condições de operação adversas, as redes são capazes de realizar computação robusta, na qual seu desempenho degrada suavemente por estar relacionado ao processamento paralelo e distribuído da rede.

2.4.1 Neurônio Artificial

A figura 4 exemplifica um neurônio artificial, que pode ser definido como uma unidade de processamento de uma rede neural.

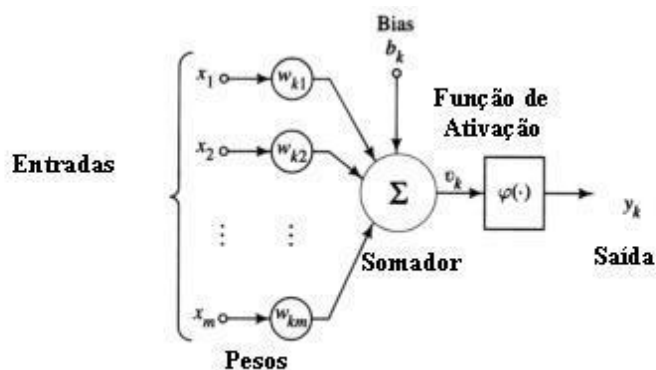


Figura 4: Neurônio Artificial.
Fonte: Ferrari (2011).

Este modelo também pode ser descrito matematicamente como:

$$u_k = \sum_{j=1}^m w_{kj} x_j \quad (1)$$

Sendo u o resultado da multiplicação entre os pesos w e as respectivas entradas x .

$$v_k = u_k + b_k \quad (2)$$

v é o potencial de ativação do neurônio ou, ainda, campo local induzido. É definido pela soma entre u (multiplicação entre pesos e entradas) e o *bias* b .

$$y_k = \varphi(v_k) \quad (3)$$

y é saída do neurônio, φ é a função de ativação.

Em resumo, podem ser destacados três elementos básicos desse modelo (HAYKIN, 2001, p. 36-37):

- Elos de conexão ou sinapses, caracterizados por pesos;
- Um somador, no qual também se encontra as *biases*, que têm a função de aumentar ou diminuir a entrada líquida da função de ativação. Ou seja, a partir dessa soma, é produzido um nível de atividade. Se esse nível exceder um limiar, chamado também de *threshold*, a unidade de processamento produzirá uma resposta de saída;

- Função de ativação, que restringe a amplitude da saída de um neurônio, existindo quatro tipos principais, os quais serão descritos na sequência:

a) Função Sigmóide ou logística: assume valores sempre positivos.




Figura 5: Função Sigmóide.
Fonte: Schnitman (1998).

A função Sigmóide possui um gráfico em forma de S e é considerada a função de ativação mais utilizada. Ela é crescente, possuindo um balanceamento adequado entre comportamento linear e não linear.

b) Função Hiperbólica: a saída pode assumir valores positivos e negativos.




Figura 6: Função Hiperbólica.
Fonte: Schnitman (1998).

Quando é desejável que a função de ativação se estenda de -1 a +1, a função assume forma anti-simétrica em relação à origem, ou seja, “a função de ativação é uma função ímpar do campo local induzido” (HAYKIN, 2001, p. 39).

c) Função Linear: usada principalmente em neurônios da camada de saída. Esse tipo de função pode ser vista como aproximação de um amplificador não-linear

e, caso a operação fique restrita à região linear (sem saturação), surge um combinador linear.




Figura 7: Função Linear.
Fonte: Schnitman (1998).

d) Função Degrau: valores rígidos.




Figura 8: Função Degrau.
Fonte: Schnitman (1998).

Segundo Haykin (2011), nesse modelo, a saída do neurônio assume o valor 1, se o campo local induzido do neurônio é não-negativo. Caso contrário, assumirá valor 0.

Um neurônio Adaline recebe sinal de diversas entradas, inclusive uma entrada unitária, a *bias*. O peso da *bias* utiliza a regra delta para ter seu valor ajustado.

Um possível algoritmo de treinamento, segundo Fausett (1993), é descrito a seguir:

- Definir os pesos e a bias;
- Definir a taxa de aprendizagem;
- A atualização dos pesos deve ser proporcional ao erro:

$$- (tp - yp) * xi \quad (4)$$

Sendo: tp – alvo (target) do neurônio para o padrão p ;

yp – saída obtida naquele padrão p ;

x_i – entrada da rede (índice i);

- Enquanto a condição de parada não for atingida, executar para cada par entrada/saída da tabela de treinamento:

$$yp = \sum_i x_i * w_i + b \quad (5)$$

$$w_i (\text{novo}) = w_i (\text{anterior}) + \alpha * - (tp - yp) * x_i$$

$$b (\text{novo}) = b (\text{anterior}) + \alpha * - (tp - yp)$$

Sendo: y – saída do neurônio;

b – peso da bias;

w_i – peso da conexão da entrada x_i ;

α – taxa de aprendizado.

- Verificação de condição de parada.

A condição de parada, no Adaline, pode ser um determinado valor de erro tolerável, seja para cada padrão, seja para um somatório de todos os erros.

O erro utilizado é o erro quadrático por padrão (EQP).

$$EQP = 0,5 * (tp - yp)^2 \quad (6)$$

Através dessa técnica, é possível desenvolver uma aplicação para reconhecimento de padrões. A técnica do Adaline trata a saída do neurônio como linear, não como “falsa” ou “verdadeira” (função degrau), como algumas técnicas conhecidas como Perceptron, regra de Hebb e o neurônio de McCulloch-Pitts.

2.4.2 Arquiteturas de rede

Existem, basicamente, dois tipos de arquitetura, quais sejam: RNA de uma camada e RNA de múltiplas camadas.

- RNA de uma camada: é composta de n entradas e m saídas, sendo que a única camada de neurônios é a própria saída.




Figura 9: RNA de uma camada.
Fonte: Palmiere (2016).

Segundo Palmiere (2016), nessa arquitetura, chamada também de FeedForward de camada simples, é possível observar, pela figura 9, que o fluxo de dados sempre segue em direção à camada de saída. Essa arquitetura é utilizada em reconhecimento de padrões e filtros. Perceptron e Adaline são algoritmos que exemplificam esse tipo de arquitetura.

- RNA de múltiplas camadas: é empregada na aproximação de funções, classificação de padrões, otimização e controle de processos.




Figura 10: RNA de múltiplas camadas.
Fonte: Palmiere (2016).

A figura 10 exemplifica essa arquitetura que, também conhecida como FeedForward de Camadas Múltiplas, é constituída por camadas escondidas de neurônios. Algoritmos que exemplificam: Perceptron Multicamadas e Redes de Base Radial.

2.4.3 Tipos de aprendizagem

Em uma RNA, a aprendizagem pode ser entendida como um procedimento de ajuste de parâmetros da rede, baseado em padrões ou estímulos apresentados a mesma. Segundo Ferrari (2011), os principais tipos de aprendizagem são: aprendizado supervisionado e aprendizado não supervisionado.

No que concerne ao primeiro tipo de aprendizagem, aprendizado supervisionado, são utilizados padrões de entrada e de saída, contendo ajuste dos pesos para minimizar os distúrbios. Ou seja, são fornecidos pares de entrada e de saída à rede, de modo que a resposta de saída seja comparada com a resposta desejada. Assim, tem-se o erro, o qual é fruto da diferença entre a resposta desejada e a resposta real.

Sobre esse aspecto, salienta-se que um método muito utilizado é aquele que se baseia no critério do erro quadrático médio. Na equação abaixo, tem-se que “ e ” é a diferença entre a resposta desejada e a resposta real.

$$EQM = \frac{\sum_{t=1}^n e_t^2}{n} \quad (7)$$

Por sua vez, no aprendizado não supervisionado, a rede procura, sem auxílio de um “professor”, estabelecer relações de padrões, regularidades etc., utilizando apenas os dados que lhe são apresentados. Nessa modalidade, o erro não é levado em consideração. A performance da rede não é avaliada em comparação com os dados de entrada. Normalmente, é utilizado um algoritmo competitivo de aprendizagem.

2.5 CONTROLADORES COM RNA

Segundo Schnitman (1998), a forma de atuação de controle, assim como os métodos de identificação, baseados em Rede Neural Artificial, podem ser classificados como controle direto ou inverso.

No que se refere ao primeiro, sabe-se que há situações em que somente o controle convencional não é eficaz, necessitando, assim, de uma intervenção humana para a realimentação de sinal; um ajuste para a próxima ação de controle, por exemplo. Nesse caso, o treinamento da RNA é associado a um modelo direto, ou seja, o sinal de entrada da rede deverá levar para a entrada da planta um sinal de controle que corresponda a ação humana, em outros termos, que corresponda a esse ajuste na ação de controle.




Figura 11: Controle Direto.
Fonte: Schnitman (1998).

Na figura 11, pode-se observar que o sinal de saída de planta é comparado com o sinal de referência e, então, enviado ao controlador, o qual realizará os ajustes necessários e, posteriormente, emitirá um novo sinal de entrada à planta, configurando, assim, a realimentação convencional.

Por seu turno, o controle inverso procura estabelecer uma relação direta entre a resposta desejada e sua respectiva ação de controle. Normalmente, é utilizado um modelo inverso, ou seja, a RNA já é treinada de modo inverso. Esse tipo de controle tem vasta aplicação na área de robótica.

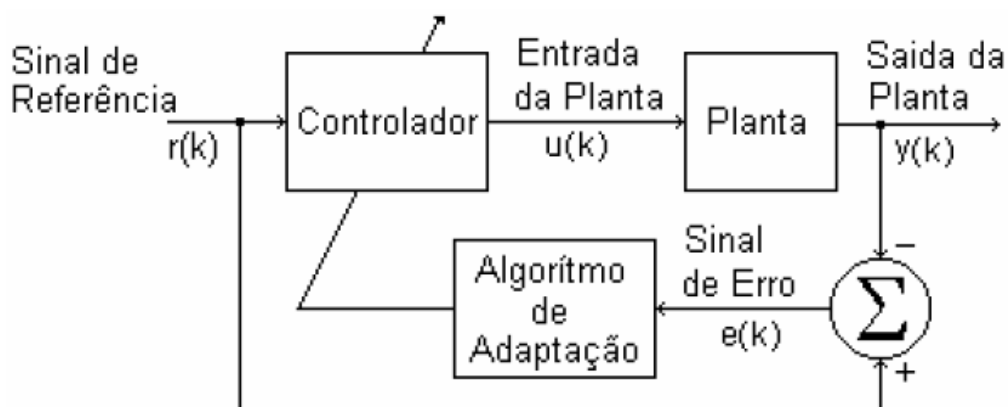


Figura 12: Controle Inverso.
Fonte: Schnitman (1998).

Na figura 12 é possível observar que o sinal de erro da planta, após o algoritmo de adaptação, retorna como entrada ao controlador, forçando, assim, uma ação de controle que leve a saída da planta a convergir para o sinal de referência.

Ainda segundo Schnitman (1998), controladores baseados em RNA podem ser divididos em subcategorias, conforme os diagramas de blocos abaixo ilustrados, nos quais $r(k)$ é o sinal de referência, $e(k)$ é o erro, $u(k)$ é o sinal de entrada da planta e $y(k)$ é o sinal de saída da planta:

a) Controle baseado em modelo de referência




Figura 13: Diagrama de controle baseado em modelo de referência.
Fonte: Schnitman (1998).

Nesse tipo de controle, o controlador é responsável por fazer com que a planta se comporte de forma semelhante ao modelo de referência. O modelo gera pares de entrada/saída desejáveis ao sistema.

b) Controle baseado em modelo interno




Figura 14: Diagrama de controle baseado em modelo interno.
Fonte: Schnitman (1998).

Nesse, o modelo de referência é colocado em paralelo com a planta. A saída da planta é comparada com a saída do modelo e, então, ocorre a realimentação para o controlador, o qual executará os ajustes necessários e enviará novo sinal de entrada à planta.

c) Controle baseado em RNA recursiva




Figura 15: Diagrama de controle baseado em RNA recursiva.
Fonte: Schnitman (1998).

Pode ser observado, em controladores neurais, que o controlador recebe direta ou indiretamente os sinais de entrada, saída ou erros associados às plantas. Nesse tipo de controlador, ressalta-se o fato da arquitetura da rede neural multicamadas possuir realimentação.

d) Controle ótimo baseado em RNA




Figura 16: Diagrama de controle ótimo baseado em RNA.
Fonte: Schnitman (1998).

Esse tipo de controlador utiliza uma rede de Kohonen como bloco de otimização. Como se trata de uma rede competitiva, há uma ponderação da dinâmica do processo através da realimentação, e uma única saída ativa é selecionada e enviada ao controlador para as devidas ações de controle.

e) Controle preditivo baseado em RNA

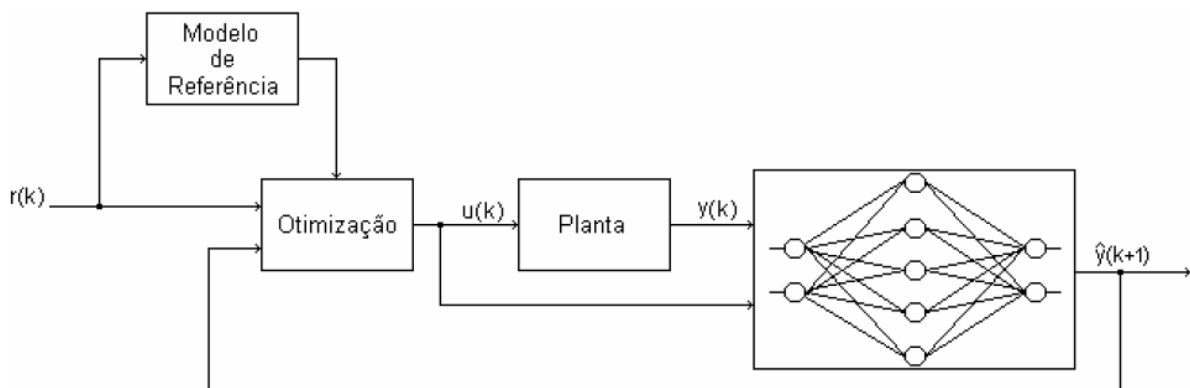


Figura 17: Diagrama de controle preditivo baseado em RNA.
Fonte: Schnitman (1998).

Na figura 17, apresenta-se a estrutura geral de um controlador preditivo baseado em RNA. Conforme é possível analisar, o modelo de referência realiza a previsão de valores futuros. Sendo que uma função de otimização e uma lei de controle geram a ação futura para o controlador. O assunto sobre controladores preditivos é bem abrangente, tendo vasta aplicação em estudos atualmente.

2.6 PLANTA DIDÁTICA DE TEMPERATURA

A planta que será utilizada neste trabalho, chamada CRT, é da marca Didacta Italia. A fim de melhor compreendê-la, apresenta-se, nesse tópico, algumas informações sobre essa planta presentes no manual do usuário. A composição da planta é apresentada na Figura 18.




Figura 18: Visão sinóptica da planta de temperatura.
Fonte: Manual do usuário – Didacta.

Seus principais elementos são:

1. Tanque de coleta de água;
2. Bomba centrífuga;
3. Válvula para ajuste manual da taxa de fluxo principal;
4. Válvula de solenoide para introduzir a interferência;
5. Válvula para ajuste manual da taxa de fluxo de interferência;
6. Válvula manual;
7. Medidor de fluxo;
8. Controlador eletrônico opcional MiniReg;
9. Equipamento Elétrico;
10. Computador pessoal (opcional);
11. Resistores de aquecimento elétricos;
12. Tanque de Pyrex com sondas PT100;
13. Válvula de descarga;
- X. Sinal ativo;

- Y. Sinal variável controlado;
- n. Sinal de ruído;
- Tmax. Sinal de termostato de segurança.

O simulador de processo CRT (Controllo Regolazione Temperatura) foi desenvolvido para o estudo das técnicas de controle de temperatura de circuito aberto e fechado. Para aquecer a água, a uma temperatura predeterminada, é necessário trabalhar os elementos de aquecimento de uma maneira consistente; em particular, com o CRT, é preciso ajustar a intensidade da corrente que passa através do resistor. Logo, a unidade de controle trabalha na intensidade da corrente que passa através do elemento de aquecimento. Por isso, uma variação no fluxo de corrente resulta em uma variação correspondente no elemento de aquecimento da temperatura do líquido. Portanto, é necessário tomar medidas para manter a temperatura constante, apesar das variações de fluxo.

Nessa medida, utilizando o CRT é possível executar ações do controle do tipo On/Off (liga/desliga) e do tipo PID (Proporcional, Integrativo, Derivativo). O controle do tipo On/Off é o mais simples. Sua ação de controle se resume a ligar e desligar o aquecedor, ou seja, com um *setpoint* predeterminado, o aquecedor é ligado, caso a temperatura esteja abaixo do requerido, e desligado, caso exceda o valor desse *setpoint*. Para evitar grandes oscilações, são estabelecidos dois limites, um acima do *setpoint* e um abaixo. A distância entre o *setpoint* e um dos dois limites é chamada de histerese.

Já no que se refere ao controle PID, o sinal de controle é o resultado da soma dos termos Proporcional, Integrativo e Derivativo. O Proporcional, como o próprio nome indica, é proporcional ao erro (diferença entre o *setpoint* e a variável controlada); o Integrativo, em conjunto com o Proporcional, integra o valor do erro em um intervalo de tempo; o Derivativo, por fim, indica a tendência, ou seja, “aplica ao sistema uma correção proporcional à velocidade com que o desvio aumenta” (MATIAS, 2002, p. 21).

3 MATERIAIS E MÉTODOS

Este trabalho parte do modelo já conhecido previamente para construir o controlador neural e suas estratégias de controle. Para tanto, foi utilizada a Observação Sistemática para a coleta de dados, empregando os valores de saída do modelo como valores de entrada da própria Planta de Temperatura.

Em termos práticos, a identificação foi realizada da seguinte forma: a) definiu-se as variáveis que interferem no sistema, quais sejam: temperatura inicial, vazão da bomba, distúrbio, percentual de tensão aplicada à resistência de aquecimento e temperatura atual (variável de saída); e b) coletou-se os dados: 100 amostras foram monitoradas através de programa desenvolvido em plataforma MATLAB.

Para o treinamento da rede, foi utilizado o Algoritmo Adaline, sendo analisadas as primeiras 40 amostras com atualização dos pesos e, após a conclusão desse treinamento, as 10 últimas amostras foram utilizadas para a validação do modelo. Maiores detalhes sobre a implementação dessa RNA podem ser encontrados em Fagundes (2014).

Com o modelo do sistema já conhecido, identificação via rede neural artificial, foi construído o controlador neural. Nessa etapa, utilizou-se a equação do modelo dada por:

$$T_F = (W_1 * T_i) + (W_2 * D) + (W_3 * F) + (W_4 * MV) + b \quad (8)$$

Onde:

T_F : Temperatura final;

W_1 : Peso 1;

T_i : Temperatura inicial;

W_2 : Peso 2;

D : Distúrbio;

W_3 : Peso 3;

F : Vazão;

W_4 : Peso 4;

MV : Variação de tensão (variável manipulada);

b : Bias.

Os valores ajustados dos pesos pela Rede Neural Artificial foram:

$$W_1: 0,5749$$

$$W_2: 0,5617$$

$$W_3: -0,0966$$

$$W_4: 0,1304$$

Tal equação foi invertida de modo que, para construir o controlador, necessite-se saber qual a variação na tensão (MV) é necessária para atingir o *setpoint* desejado com os respectivos parâmetros de entrada disponíveis.

$$MV = -(12.7413 + 0.5749 \cdot Ti + 0.5617 \cdot D - 0.0966 \cdot F - \text{valorSP}) / 0.1304 \quad (9)$$

Ademais, necessitou-se também fazer uma pequena conversão no valor da MV calculada, pois foi observado que o aquecimento só iniciava quando o valor enviado de MV à planta estava acima de 50. Utilizando uma variável “valor”, realizou-se a conversão segundo a equação abaixo:

$$\text{valor} = ((MV \cdot 42) / 100) + 58 \quad (10)$$

Dessa forma, criou-se um controlador conforme diagrama abaixo:




Figura 19: Diagrama Controlador Neural.

Pode-se perceber que a saída do modelo é a própria entrada da planta, e a temperatura de saída é reenviada como nova temperatura inicial para cálculo no modelo. Ou seja, a temperatura inicial é atualizada para que a MV seja calculada adequadamente e o aquecimento/resfriamento, conseqüentemente, aconteça de forma correta.

4 ANÁLISE DOS DADOS

Em vista da metodologia antes expressa, utilizando uma programação já adequada para controle na plataforma MATLAB, foram realizadas alterações e inclusões no programa para utilizar o controlador neural. Assim, foram realizados os primeiros testes.

Os parâmetros utilizados no *software* foram:

- Intervalo de amostragem: 1 segundo;
- Quantidade de amostras: 300;
- Vazão da bomba: 12 L/h;
- Temperatura inicial: lida diretamente do sistema.

Partindo de temperatura ambiente ao ligar a planta e iniciar o processo, o modelo apresentou boa aproximação ao *setpoint* requerido. Mas partindo de temperaturas acima da condição ambiente, o sistema estabilizava acima do *setpoint*.




Figura 20: Resultado Teste 1 - Aquecimento.

Na figura 20, observa-se, no eixo horizontal, o intervalo de tempo decorrido em segundos e, no eixo vertical, a escala de temperatura em °C. A temperatura inicial era 26°C aproximadamente, e o *setpoint* desejado de 30°C.




Figura 21: Resultado Teste 2 - Aquecimento.

Na figura 21, a temperatura inicial era 29°C, e o *setpoint* desejado era 35°C. Ou seja, estabilizou-se com aproximadamente 5°C, acima do requerido.

Devido a essa condição, foi necessário realizar alguns ajustes no modelo utilizado, isto é, na equação encontrada. Como foi verificado que o problema ocorria quando a temperatura inicial do processo estava acima da condição ambiente, ocasionando a estabilização acima do *setpoint*, foi incluído um fator de proporcionalidade, reduzindo um pouco a MV, para esse caso.

Tal redução partiu do método por tentativa e erro. Primeiramente, o resultado obtido foi reduzido pela metade. Assim, verificou-se que a redução foi além do necessário, visto que o sistema estabilizou abaixo do *setpoint*. Na sequência, fazendo ajustes e observando os gráficos, foi encontrado o valor ideal para essa redução proporcional, ficando estabelecida a ação de controle para temperaturas iniciais acima de 29°C:

$$valor = (((MV * 42) / 100) + 58) * 0.82 \quad (11)$$

Como já mencionado, a temperatura inicial é atualizada a todo instante e, devido a um laço de repetição, a MV é recalculada e enviada à planta a todo instante também.

As figuras a seguir são relativas aos testes realizados após o ajuste mencionado. Os eixos verticais indicam temperatura em °C , e os horizontais, o intervalo de tempo decorrido em segundos.




Figura 22: Resultado Teste 3 - Aquecimento.

Na figura 22, já com o fator de proporcionalidade adicionado à equação, é possível observar que o problema anterior, com o sistema partindo de uma temperatura acima da ambiente, foi corrigido de modo eficaz. Nota-se, nesse caso, que a temperatura inicial era de 30°C e o *setpoint* aplicado de 35°C.




Figura 23: Resultado Teste 4 - Aquecimento.

Na figura 23, partiu-se da temperatura inicial de 32°C e o *setpoint* de 37°C.




Figura 24: Resultado Teste 5 - Aquecimento.

Na figura 24, tem-se a temperatura inicial de aproximadamente 27°C e o *setpoint* de 30°C.

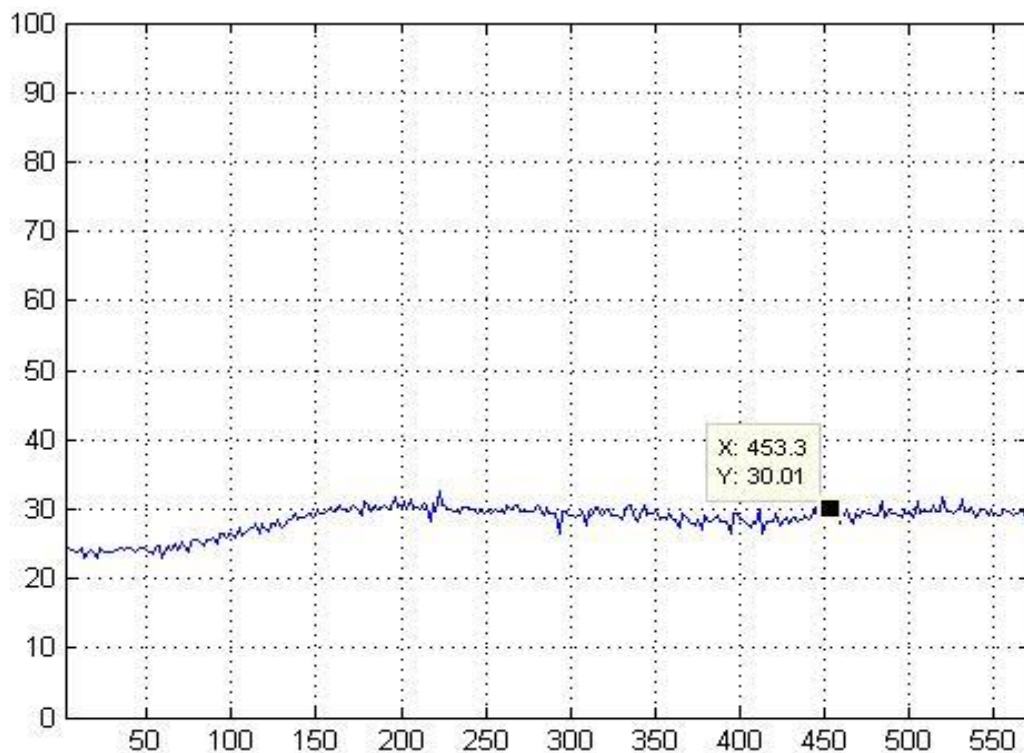


Figura 25: Resultado Teste 6 - Aquecimento.

Na figura 25, tem-se Temperatura Inicial de aproximadamente 24°C e *setpoint* de 30°C. Esse teste foi importante para observar que o ajuste realizado não interferiu nas condições de início do processo abaixo de 29°C.

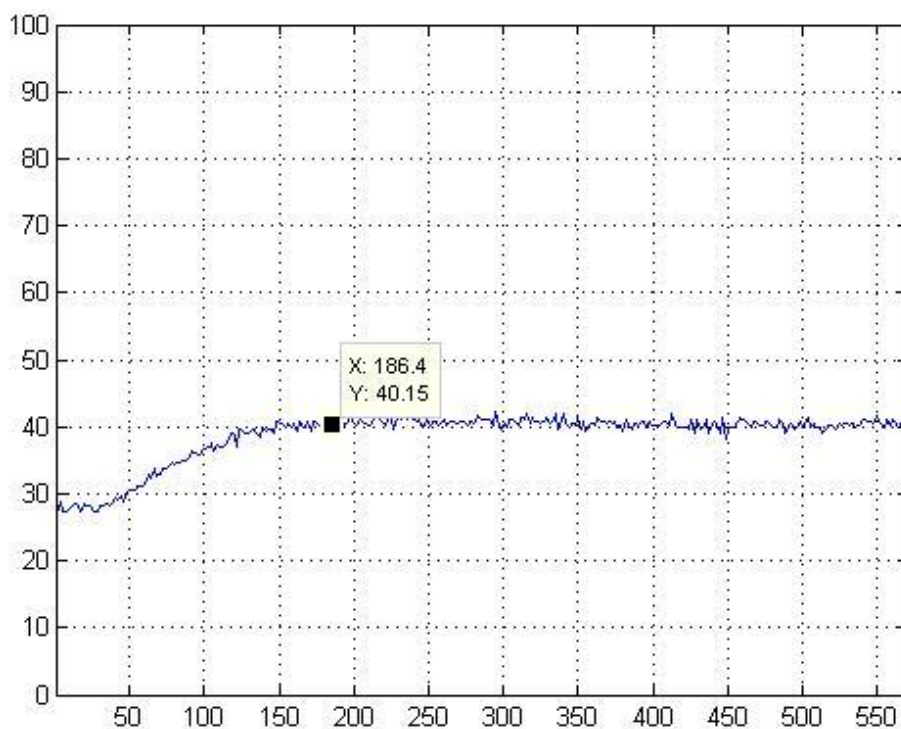


Figura 26: Resultado Teste 7 - Aquecimento.

Na figura 26, tem-se a temperatura inicial do sistema de aproximadamente 29°C e o *setpoint* de 40°C.




Figura 27: Resultado Teste 8 - Aquecimento.

Na figura 27, tem-se a temperatura inicial de aproximadamente 34°C e o *setpoint* de 40°C.

Realizou-se, ainda, o teste aplicando um *setpoint* com valor menor que a temperatura inicial para analisar o desempenho do controlador em uma condição de resfriamento.




Figura 28: Resultado Teste 9 - Resfriamento.

Na figura 28, é possível ver o resfriamento do sistema, sendo a temperatura inicial de 40°C e o *setpoint* de 35°C. Para resfriar, o tempo para estabilização do sistema é maior, portanto, foi utilizada uma faixa de tempo melhor para observação.

Nas análises até aqui realizadas, verificou-se que o Controlador Neural se mostrou satisfatório para a prática aplicada. Contudo, ainda assim, julga-se importante compará-lo com outros tipos de controladores convencionais para se obter uma boa visualização de sua eficácia.

Nesse sentido, foi executado o controle do tipo PID (Proporcional, Integrativo e Derivativo), utilizando o *software* específico da própria planta CRT. Para se obter melhor comparação, foram empregadas condições semelhantes ao outro controle, por exemplo, vazão da bomba e temperaturas iniciais, e intervalo de tempo.

Os parâmetros de PID foram:

- Banda Proporcional (P): 20%
- Integrativo (I): 10 min.
- Derivativo (D): 2 min.

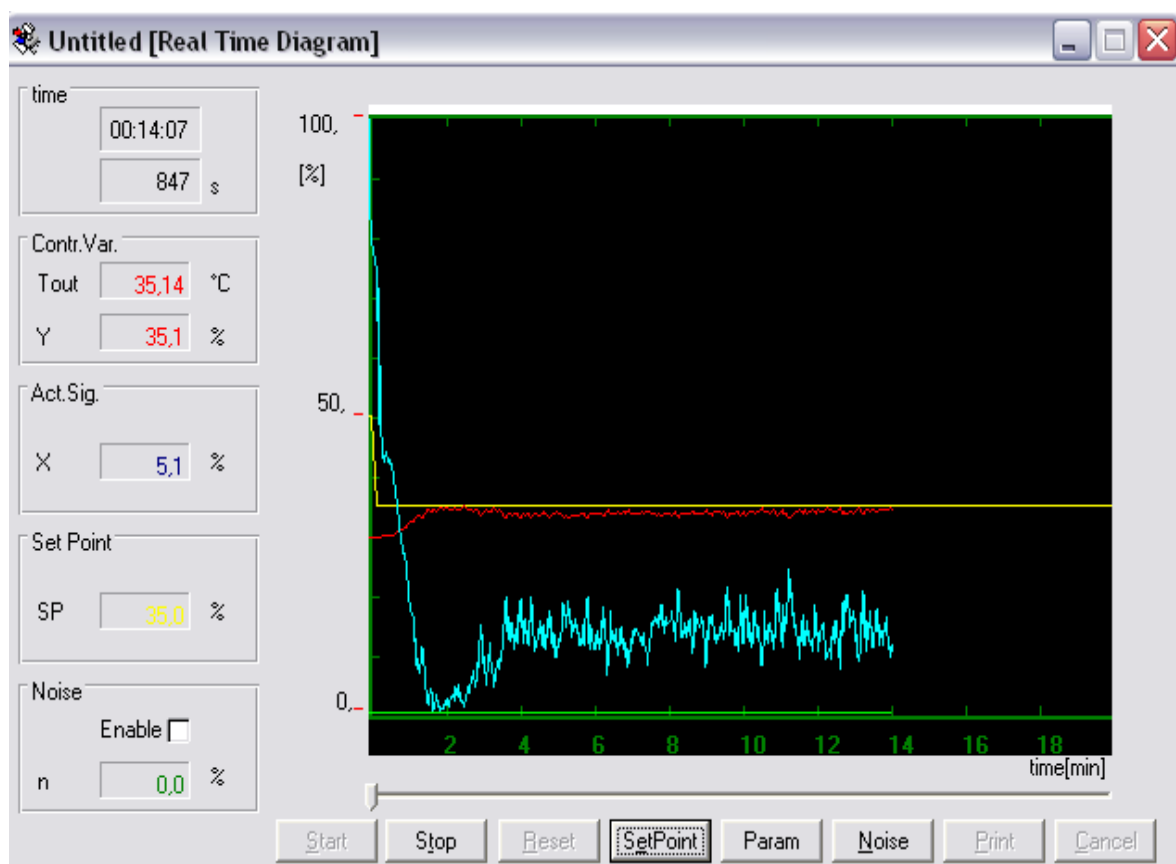


Figura 29: Resultado 1 Controle PID - Aquecimento.

Na figura 29, é possível visualizar o resultado do controle utilizando PID. A temperatura inicial é de aproximadamente 29°C e o *setpoint* de 35°C.

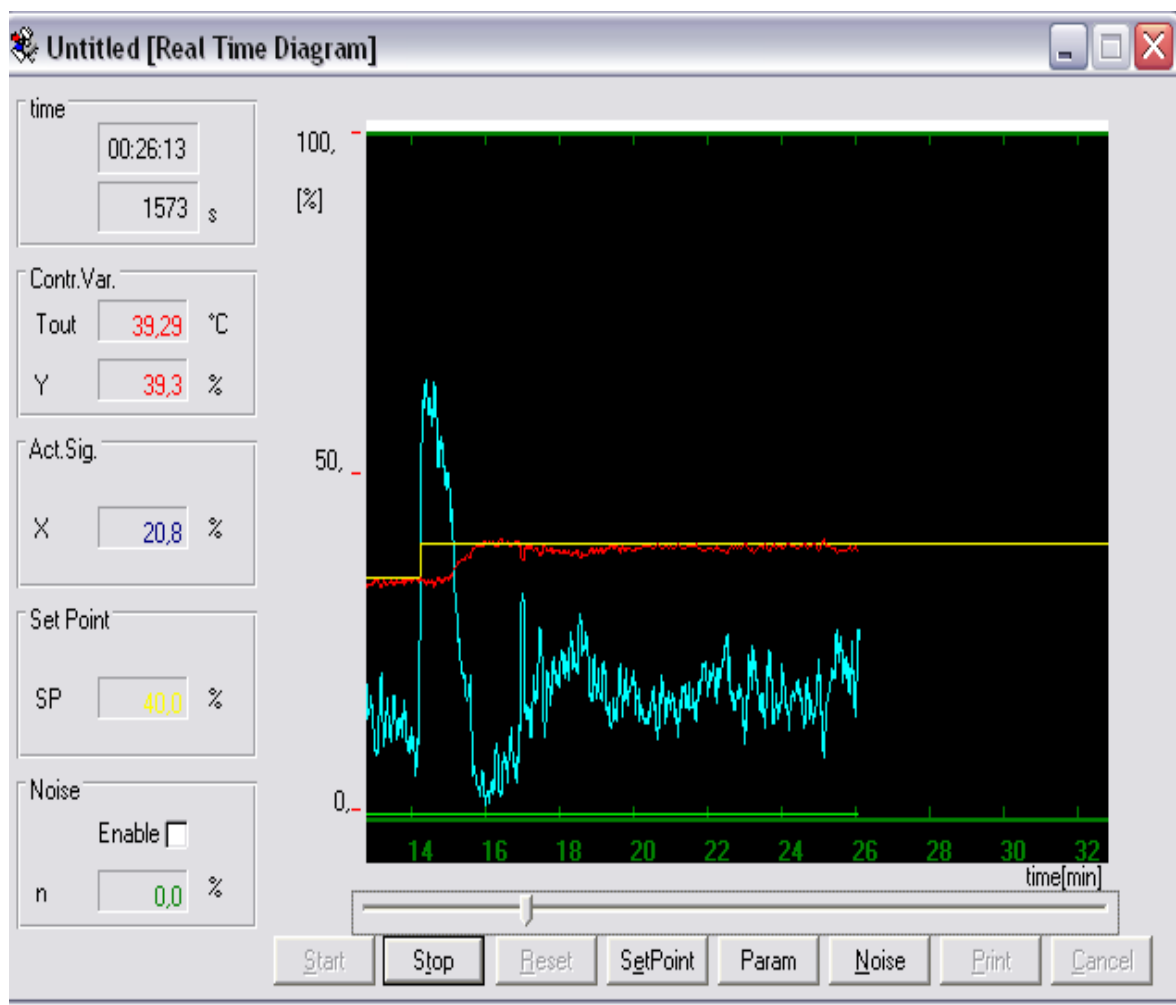


Figura 30: Resultado 2 Controle PID – Aquecimento.

Na figura 30, tem-se temperatura inicial de aproximadamente 34,1°C e *setpoint* de 40°C.

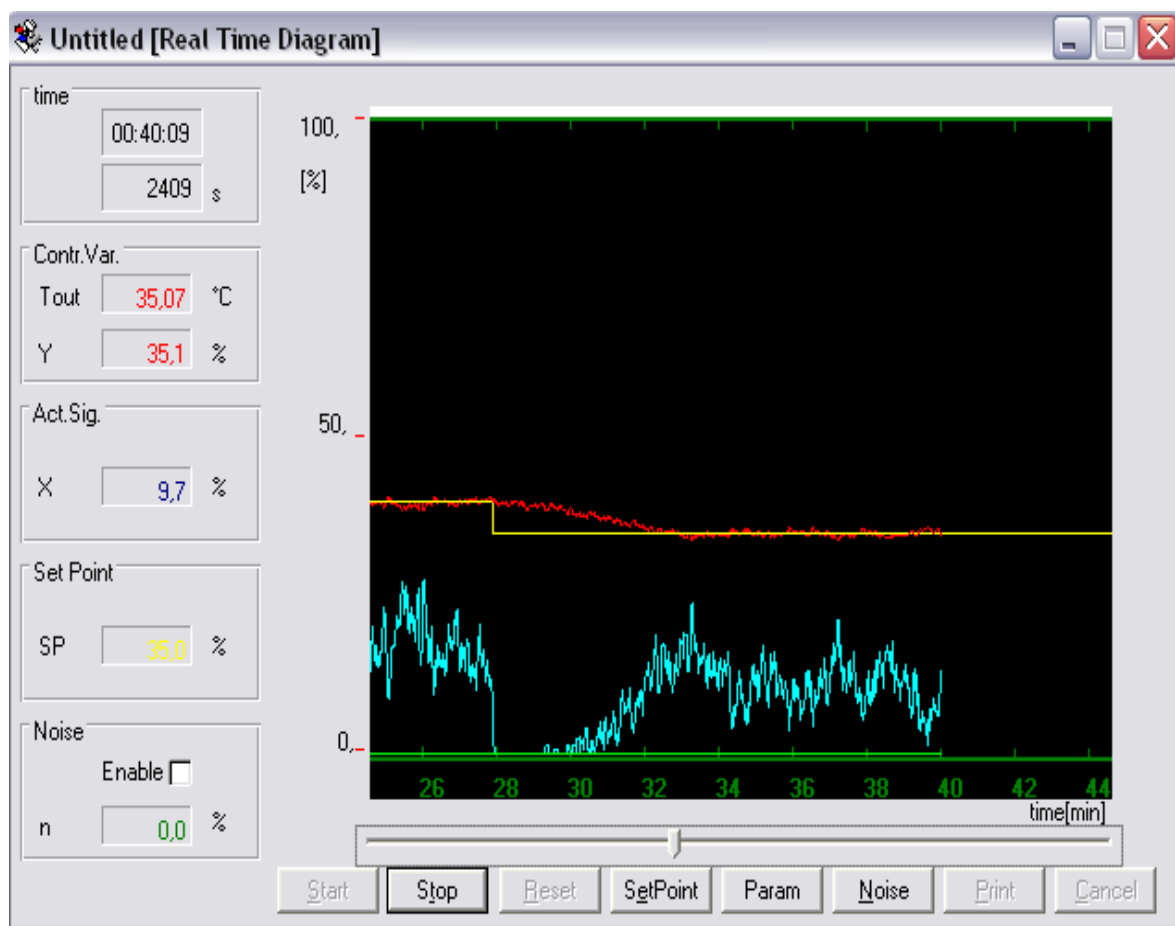


Figura 31: Resultado 3 Controle PID – Resfriamento.

Na figura 31, ilustra-se o processo de resfriamento, ou seja, o *setpoint* é uma temperatura abaixo da temperatura inicial do processo. Nesse caso, temperatura inicial é de aproximadamente 39,4°C e o *setpoint* de 35°C.

5 RESULTADOS

Utilizando os gráficos do Controlador Neural e a tabela de valores do Controlador PID, ambos extraídos de seus respectivos *softwares*, foram construídos gráficos de comparação. Para se estabelecer uma melhor relação, de forma não tendenciosa, como já mencionado, condições como temperatura inicial, vazão da bomba e intervalo de tempo foram as mesmas nos controladores. Assim, foram coletados os valores de temperatura de saída do sistema a cada 20 segundos de cada controlador.

Para os processos de aquecimento, foram analisados os desempenhos dos controladores em um intervalo de tempo de 540 segundos (9 minutos). Para o resfriamento, de 720 segundos (12 minutos).

Salienta-se que alguns fatores influenciam nesse tipo de sistema utilizado, por exemplo, com o decorrer do tempo na realização de testes, a bomba centrífuga apresenta aquecimento excessivo, interferindo na temperatura do líquido que passa por ela. Além disso, foi observado também uma pequena influência da temperatura ambiente no recinto.

Tendo em vista a análise gráfica, na qual o eixo horizontal se refere ao intervalo de tempo em segundos e o eixo vertical à temperatura em °C, é possível constatar o melhor desempenho do Controlador Neural em relação ao Controlador PID:

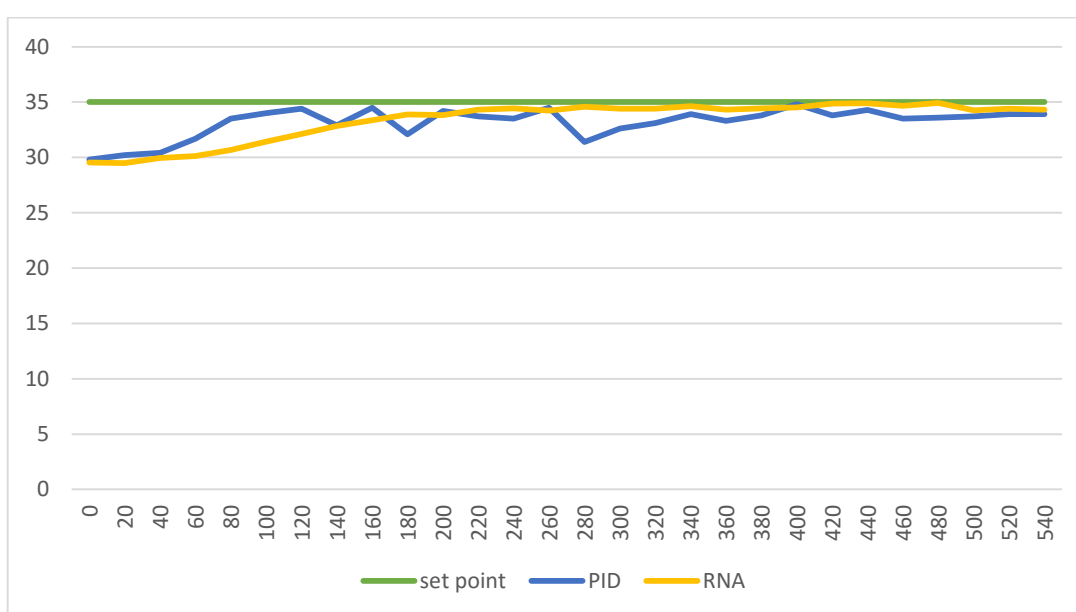


Gráfico 1: Comparativo entre Controladores - Aquecimento.

No gráfico 1, é estabelecido um comparativo de desempenho entre os controladores, partindo da temperatura inicial um pouco abaixo de 30°C e com *setpoint* de 35°C. Vale ressaltar que o método empregado para a análise foi baseado na temperatura.




Gráfico 2: Comparativo entre Controladores – Aquecimento.

No gráfico 2, tem-se a temperatura inicial de aproximadamente 34°C e o *setpoint* de 40°C.




Gráfico 3: Comparativo entre Controladores – Resfriamento.

No gráfico 3, tem-se a situação de resfriamento, ou seja, o *setpoint* requerido está abaixo da temperatura inicial. Como já mencionado anteriormente, para o resfriamento foi utilizado um intervalo de tempo maior, para melhor observação. Nessa medida, tem-se temperatura inicial de aproximadamente 40°C e *setpoint* de 35°C.

6 CONCLUSÕES

O trabalho aqui apresentado pode ser considerado satisfatório. O objetivo de se trabalhar estratégias de controle envolvendo Rede Neural Artificial e conceitos de controle moderno para aplicação de controle na planta didática de temperatura, localizada no laboratório de Automação e Controle, foi alcançado com êxito.

Salienta-se, no entanto, que algumas dificuldades foram encontradas, como a restrição do modelo utilizado, a qual foi devidamente tratada. Ademais, a complexidade do assunto e também questões físicas na planta estudada, como, por exemplo, a bomba centrífuga, ocasionaram contratempos. No que concerne à bomba centrífuga, devido ao seu dimensionamento e tempo de operação, constatou-se a presença de um excessivo aquecimento, interferindo na temperatura final do sistema e comprometendo seu resfriamento.

Em comparação com o Controlador PID convencional, por análise gráfica, foi possível verificar a eficácia do controlador desenvolvido para a aplicação utilizada. Nessa medida, acredita-se que, a partir deste trabalho, novas aplicações podem ser desenvolvidas, tanto para plantas didáticas quanto para indústrias, isso porque o controle moderno é muito abrangente e a cada dia se descobre mais funcionalidades. Logo, este trabalho proporcionou a aplicação dos conhecimentos adquiridos durante o curso e também a oportunidade de novos conhecimentos, ampliando, assim, a visão e a compreensão profissional e acadêmica da Automação Industrial.

REFERÊNCIAS

AGUIRRE, L. A. **Introdução à Identificação de Sistemas: Técnicas Lineares e Não Lineares Aplicadas a Sistemas Reais**. 3. ed. rev. e ampl. Belo Horizonte: Editora UFMG, 2007a.

AGUIRRE, L. A. **Enciclopédia de automática: controle e automação**. Volume 2. São Paulo: Blucher, 2007b.

DIDACTA. **Automation and Process Control: CRT – Temperature Control and Regulation Unit**. 1. ed. 18 p.

FAGUNDES, F. D. **Identificação de Sistemas com Redes Neurais Artificiais**. 2014. Dissertação (Mestrado em Engenharia Elétrica) - Programa de Pós-Graduação em Engenharia Elétrica, Universidade Federal de Uberlândia, Uberlândia, 2014.

FAUSETT, L. **Fundamentals of Neural Networks: Architectures, Algorithms and Applications**. 1. ed. New Jersey: Pearson, 1993. 461 p.

FERRARI, A. C. K. **Controlador PID sintonizado por Redes Neurais Artificiais**. 2010. 63 f. Trabalho de Conclusão de Curso (Engenharia Elétrica) – Universidade Federal do Paraná, Curitiba, 2010. Disponível em: <<http://www.eletrica.ufpr.br/ufpr2/tccs/190.pdf>>. Acesso em: 29 nov. 2014.

HAYKIN, S. **Redes Neurais: Princípios e Prática**. 2. ed. Porto Alegre: Bookman, 2001.

MATIAS, J. Teoria de controle PID. **Revista Mecatrônica Atual**, São Paulo, n. 3, p. 17-25, abr. 2002. Disponível em: <http://coral.ufsm.br/beltrame/arquivos/disciplinas/medio_automacao_industrial/Artigo_Teoria_controle_PID.pdf>. Acesso em: 01 jun. 2016.

NISE, N. S. **Engenharia de sistemas de controle**. 5. ed. Rio de Janeiro: LTC, 2009.

OGATA, K. **Engenharia de Controle Moderno**. 4. ed. São Paulo: Prentice Hall, 2003.

PALMIERE, S. E. **Inteligência Artificial – Arquiteturas e Topologias de Redes Neurais Artificiais**. Disponível em: <<http://www.embarcados.com.br/arquiteturas-e-topologias-de-redes-neurais-artificiais/>>. Acesso em: 28 jun. 2016.

PROTTES, S. M. **Controlador Neural Preditivo Multivariável Aplicado a uma planta piloto de neutralização de pH**. 2009. 132 f. Dissertação (Mestrado em Engenharia) - Centro Universitário do Leste de Minas Gerais, Coronel Fabriciano, 2009. Disponível em: <http://www.unilestemg.br/portal/mestrado/dissertacoes/dissertacao_017.pdf>. Acesso em: 20 out. 2015.

SCHNITMAN, L. **Controladores Preditivos baseados em Redes Neurais Artificiais**. 1998. 136 f. Dissertação (Mestrado em Engenharia Elétrica) – Universidade Federal da Bahia, Salvador, 1998. Disponível em: <<http://www.ppgee.eng.ufba.br/teses/3fa84f4664183cab6c0c9022d582c762.pdf>>. Acesso em: 20 mai. 2016.