



UNIVERSIDADE FEDERAL DO OESTE DA BAHIA  
Centro Multidisciplinar de Bom Jesus da Lapa  
**Colegiado do Curso de Engenharia Elétrica**

GENILDO DIAS SANTOS

# **APLICAÇÃO DE REDES NEURAIS ARTIFICIAIS PARA CONTROLE DE CARGA EM MOTORES DE INDUÇÃO**

Bom Jesus da Lapa–BA  
Setembro de 2024

**UNIVERSIDADE FEDERAL DO OESTE DA BAHIA**

Centro Multidisciplinar de Bom Jesus da Lapa

Colegiado do Curso de Engenharia Elétrica

Genildo Dias Santos

**APLICAÇÃO DE REDES NEURAIS ARTIFICIAIS PARA  
CONTROLE DE CARGA EM MOTORES DE INDUÇÃO**

*Trabalho de conclusão de curso apresentado ao Colegiado do Curso de Engenharia Elétrica do Centro Multidisciplinar de Bom Jesus da Lapa da Universidade Federal do Oeste da Bahia, como requisito parcial para obtenção do grau de Bacharel em Engenharia Elétrica.*

Orientador: Prof. Dr. Kleymlson do Nascimento Souza

Coorientador: Prof. Me. Ademário José de Carvalho Neto

Bom Jesus da Lapa-BA

Setembro de 2024

## FICHA CATALOGRÁFICA

---

S237

Santos, Genildo Dias

Aplicação de Redes Neurais Artificiais para controle de carga em Motores de Indução. / Genildo Dias Santos. – 2024.

70f.: il.

Orientador: Prof. Dr. Kleymilson do Nascimento Souza

Coorientador: Prof. Me. Ademário José de Carvalho Neto

TCC - Graduação em Engenharia Elétrica, Universidade Federal do Oeste da Bahia. Centro Multidisciplinar de Bom Jesus da Lapa - BA, 2024.

1. Redes Neurais. 2. Motores Elétricos de Indução. I. Souza, Kleymilson do Nascimento. II. Universidade Federal do Oeste da Bahia – Centro Multidisciplinar de Bom Jesus da Lapa - BA. III. Título.

CDD 006.32

---

**Biblioteca Universitária de Bom Jesus da Lapa – UFOB**

# **FOLHA DE APROVAÇÃO**

**GENILDO DIAS SANTOS**

## **APLICAÇÃO DE REDES NEURAIS ARTIFICIAIS PARA CONTROLE DE CARGA EM MOTORES DE INDUÇÃO**

Bom Jesus da Lapa, 05 de Setembro de 2024

---

Prof. Dr. Kleymilson do Nascimento Souza (UFOB)  
(Orientador)

---

Prof. Me. Ademário José de Carvalho Neto (UFOB)  
(Coorientador)

---

Prof. Dr. Manoel Messias Silva Júnior (UFOB)

---

Prof. Ma. Andressa Pereira Oliveira (UFOB)

*Esta monografia é dedicada à minha avó, Maria Senhora Brito (in memoriam) e aos meus pais, Dinalva Santos e João Batista Santos, que sempre sonharam em me verem Engenheiro.*

---

## Agradecimentos

Agradeço,

À Deus, porque sem Ele, nada teria sido possível.

Aos meus pais, Dinalva Santos e João Batista Santos, por serem minha base e me concederem apoio incondicional em todos os momentos da trajetória.

Aos meus orientadores, Me. Ademário Carvalho e Dr. Kleymilson Souza, que me oportunizaram instruir na elaboração desse trabalho, pelo apoio, pela paciência e pelos conhecimentos transmitidos.

A Dr. Jorge Luís Santos, por me conceder a oportunidade de me orientar por três anos em trabalhos de iniciação científica.

A todos os professores que contribuíram para a minha formação acadêmica, pelo compartilhamento dos seus conhecimentos e valores.

Ao Eng. Luís Cláudio Gomes, por conceder a oportunidade de exercer o estágio na sua instituição.

Aos meus amigos que cultivei durante a graduação, em especial a Raphael Diniz, Iuri Benedito, Tarcisio Pires, Felipe Santana, Ralf Silva e Lucas Natan Aguiar.

Aos colaboradores da UFOB do campus de Bom Jesus da Lapa, que de alguma forma me incentivaram e apoiaram nesse período.

“O conhecimento é como a eletricidade, é  
uma forma de energia que ilumina a mente.”

(Autor Desconhecido)

---

## Resumo

A evolução de sistemas e tecnologias que possam melhorar os aspectos de operação dos Motores de Indução Trifásicos (MIT) traz consequência para sociedade, uma vez que são amplamente difundidos nos diversos ramos da indústria. O avanço e aperfeiçoamento das tecnologias, tem levado pesquisadores a implementarem ferramentas usadas para identificação e controle de sistemas dinâmicos, que podem ser aplicadas no motor de indução. Uma dessas ferramentas é a Rede Neural Artificial (RNA), que possui as características de aprender, generalizar, classificar e organizar dados a partir do treinamento. O presente trabalho apresenta o desenvolvimento do controle de carga em motor de indução através da aplicação de RNA, realizando o estudo de uma bancada didática que simula cargas em um motor de indução através de um freio magnético. Os dados apresentados pela bancada têm um comportamento não linear dinâmico na resposta de velocidade para sinais de frenagem aplicados na entrada dos tipos senoide, rampa e degrau. Com o intuito de controlar as características dinâmicas do sistema, foi desenvolvida uma RNA e realizado o seu treinamento, o algoritmo foi desenvolvido no *software* MATLAB®. A rede neural buscou responder aos dados de entrada da maneira mais satisfatória e próxima de uma saída desejada. Foi implementado e analisado dois tipos de sinais, o senoide e rampa. De acordo com os resultados apresentados neste trabalho, foi demonstrado que a arquitetura da Rede Neural Artificial utilizada (*feedforward* de múltiplas camadas) para os sinais aplicados foi satisfatória. A rede neural conseguiu aprender o funcionamento do sistema e gerar resultados capazes de realizar o controle e compensações necessárias, alcançado comportamentos próximos aos almejados.

**Palavras-chave:** Redes Neurais Artificiais, Motor de Indução, Sistema Dinâmico.

---

## Abstract

The evolution of systems and technologies that can improve the operational aspects of Three-Phase Induction Motors (MIT) has consequences for society, since they are widely disseminated in different branches of industry. The advancement and of technologies has led researchers to implement tools used to identify and control dynamic systems, which can be applied to the induction motor. One of these tools is the *Artificial Neural Network* (ANN), which has the characteristics of learning, generalizing, classifying and organizing data from training. The present work studies the development of load control in an induction motor through the application of ANN, carrying out the study of a didactic bench that simulates loads in an induction motor through a magnetic brake. The data presented by the bench has a dynamic non-linear behavior in the speed response to braking signals applied to the sinusoid, ramp and step input types. In order to control the dynamic characteristics of the system, an ANN was developed and trained, the algorithm was developed in MATLAB<sup>®</sup> software. The neural network aims to answer to the input data in the most satisfactory way and close to a desired output. Two types of signals were implemented and analyzed, sinusoid and ramp. According to the results presented in this work, it was demonstrated that the architecture of the Artificial Neural Network used (multi-layer feedforward) for the applied signals was satisfactory. The neural network was able to learn how the system works and generate results capable of carrying out the necessary control and compensation, achieving behaviors close to those desired.

**Keywords:** Induction motor, Electromagnetic brake, didactic bench, embedded systems, Artificial Neural Network.

---

---

## Lista de Figuras

1	Sinais elementares . . . . .	25
2	Sinal PWM . . . . .	26
3	Motor de indução da marca WEG . . . . .	27
4	Estator típico de um motor de indução . . . . .	27
5	Típico rotor gaiola de esquilo . . . . .	28
6	Vista em corte de um motor de indução de rotor bobinado . . . . .	29
7	Circuito equivalente de <i>Thevenin</i> do rotor . . . . .	29
8	Curva característica do torque versus velocidade de um MIT . . . . .	30
9	Neurônio artificial . . . . .	31
10	Representação da função limiar unipolar . . . . .	32
11	Representação da Função Limiar Bipolar . . . . .	33
12	Representação gráfica da Função Sigmóide . . . . .	34
13	Representação gráfica da função tangente hiperbólica . . . . .	35
14	Rede <i>Feedforward</i> de Camada Única . . . . .	36
15	Redes <i>Feedforward</i> de Múltiplas Camadas . . . . .	37
16	Rede Neural <i>Feedback</i> . . . . .	38
17	Bancada de simulação . . . . .	39
18	Motor da Bancada . . . . .	40
19	Pinos do PIC 18F4550 . . . . .	42
20	Placa da Unidade de Controle . . . . .	43
21	Fonte DC de 36 V . . . . .	43
22	Placa do <i>drive</i> de potência . . . . .	44
23	Adesivo reflexivo no <i>optor coupling</i> . . . . .	45
24	Placa do sensor RPM . . . . .	45
25	Diagrama de comunicação entre os principais componentes eletrônicos da bancada . . . . .	46

26	Esquema de ligação . . . . .	47
27	Sinais de frenagem . . . . .	48
28	Sinais de entrada em degraus e saída . . . . .	49
29	Sinais de entrada em rampa e saída . . . . .	50
30	Sinais de entrada senoidal e saída . . . . .	50
31	Sinais de entrada senoidal . . . . .	52
32	Sinais de entrada em rampa de 0% a 100% e 20% a 40% de <i>duty cycle</i> . . .	52
33	Sinais de entrada em rampa de 40% a 60% e 50% a 70% <i>duty cycle</i> . . . .	53
34	Dispositivo de aquisição <i>National Instruments</i> (NI) USB-6009 . . . . .	53
35	Diagrama básico para coleta de dados . . . . .	54
36	Sinais de entrada senoidal e sinal de saída em RPM . . . . .	55
37	Sinais de entrada em rampa e sinal de saída em RPM . . . . .	55
38	Diagrama de funcionamento da Bancada sem e com a aplicação de RNA .	56
39	Arquitetura e treinamento da RNA para o sinal senoide . . . . .	59
40	Gráfico da performance da RNA para o sinal senoide . . . . .	60
41	Gráficos de regressão no treinamento para o sinal senoide . . . . .	60
42	Sinais de referência e o fornecido pela RNA . . . . .	61
43	Gráficos dos dados separados e dos fornecidos pela rede para o sinal senoidal	61
44	Treinamento e arquitetura da rede para o sinal em rampa . . . . .	62
45	Gráfico da performance da RNA para o sinal em rampa . . . . .	63
46	Gráfico da performance da RNA para o sinal em rampa . . . . .	63
47	Sinal de referência e sinal fornecido pela RNA . . . . .	64
48	Gráficos dos dados separados e dos fornecidos pela rede para o sinal em rampa . . . . .	64

---

## Lista de Tabelas

1	Valores de erro para $N^\circ$ de neurônios em cada camada da RNA para o sinal senoidal . . . . .	59
2	Valores dos 10 menores erros para $N^\circ$ de neurônios em cada camada da RNA para o sinal em rampa . . . . .	62

---

## Lista de quadros

1	Informações técnicas do motor de indução . . . . .	41
---	--	----

---

## Lista de abreviaturas, acrônimos e siglas

<b>ANN</b>	<i>Artificial Neural Network</i>
<b>RPM</b>	Rotação Por Minuto
<b>A/D</b>	Analógico/Digital
<b>AWG</b>	<i>American Wire Gauge</i>
<b>cv</b>	Cavalo-Vapor
<b>CI</b>	Circuitos Integrados
<b>DC</b>	<i>Direct Current</i>
<b>DTC</b>	<i>Direct Torque Controlled</i>
<b>IA</b>	Inteligencia Artificial
<b>IC</b>	Inteligência Computacional
<b>ICSP</b>	<i>In-Circuit Serial Programming</i>
<b>MATLAB</b>	<i>MAtrix LABoratory</i>
<b>MIT</b>	Motores de Indução Trifásicos
<b>MSE</b>	<i>Mean Squared Error</i>
<b>NI</b>	<i>National Instruments</i>
<b>PIC</b>	<i>Programmable Intelligent Computer</i>
<b>PC</b>	<i>Personal Computer</i>
<b>PWM</b>	<i>Pulse-Width Modulation</i>
<b>RNA</b>	Rede Neural Artificial
<b>STCZT</b>	<i>Short Time Chirp-Z Transform</i>
<b>USB</b>	<i>Universal Serial Bus</i>

---

## Lista de Símbolos

Hz	Hertz
A	Ampère
V	Volt
cv	Cavalo Vapor
mm	Milímetros
W	Watt
$\Sigma$	Somatório
$y_k$	Saída do neurônio artificial
$f(u_k)$	Função de ativação
$x_j$	Valores de entrada no neurônio artificial
$w_{kj}$	Sinaps
$b_k$	Bias
$t$	Tempo
$a$	parâmetro de inclinação
$b$	limites inferiores e superiores
$DC$	<i>duty cycle</i>
$LP$	Largura de pulso
$T$	período
$e$	- Mean Squared Error ( $MSE$ ) (Erro Médio Quadrático);
$y_i$	Dados de saída iniciais
$y_{rna_i}$	Dados de saída da RNA
$i$	Elemento do somatório
$n$	Último elemento do somatório

---

---

# Sumário

<b>1</b>	<b>INTRODUÇÃO</b>	<b>16</b>
1.1	OBJETIVO GERAL . . . . .	18
1.2	OBJETIVOS ESPECÍFICOS . . . . .	18
1.3	JUSTIFICATIVA . . . . .	18
1.4	ORGANIZAÇÃO DO TEXTO . . . . .	20
<b>2</b>	<b>REVISÃO BIBLIOGRÁFICA</b>	<b>21</b>
<b>3</b>	<b>FUNDAMENTAÇÃO TEÓRICA</b>	<b>24</b>
3.1	SINAIS ELEMENTARES . . . . .	24
3.2	SINAL PWM . . . . .	25
3.3	MOTORES DE INDUÇÃO TRIFÁSICOS . . . . .	26
3.3.1	Motor de Indução com Rotor tipo Gaiola . . . . .	28
3.3.2	Motor de Indução com Rotor tipo Bobinado . . . . .	28
3.3.3	Curva de velocidade <i>versus</i> torque . . . . .	29
3.4	REDES NEURAIS ARTIFICIAIS . . . . .	30
3.4.1	Neurônio Artificial . . . . .	30
3.4.2	Função de Ativação . . . . .	32
3.4.3	Arquitetura de Redes Neurais Artificiais . . . . .	35
<b>4</b>	<b>BANCADA DE SIMULAÇÃO</b>	<b>39</b>
4.1	MOTOR DA BANCADA . . . . .	40
4.2	UNIDADE DE CONTROLE . . . . .	41
4.3	<i>DRIVE</i> DE POTÊNCIA . . . . .	43
4.4	SENSOR DE ROTAÇÃO . . . . .	44
4.5	FUNCIONAMENTO DA BANCADA . . . . .	46
<b>5</b>	<b>METODOLOGIA</b>	<b>51</b>

5.1	SINAIS DE FRENAGEM . . . . .	51
5.2	AQUISIÇÃO DE DADOS . . . . .	53
5.3	IMPLEMENTAÇÃO DA REDE NEURAL ARTIFICIAL . . . . .	56
5.3.1	ARQUITETURA . . . . .	57
5.3.2	TREINAMENTO . . . . .	57
<b>6</b>	<b>CONCLUSÃO</b>	<b>65</b>
	<b>REFERÊNCIAS</b>	<b>68</b>

---

## INTRODUÇÃO

Atualmente, os motores elétricos são amplamente utilizados em diversos setores da indústria, sendo, muitas vezes, destinados ao acionamento de uma grande variedade de cargas. Os motores de indução recebem uma atenção especial, uma vez que apresentam um bom desempenho, uma baixa manutenção e uma boa eficiência, além de serem robustos e confiáveis (FRANCHI, 2018). Esses equipamentos representam aproximadamente 68% no consumo de energia elétrica do setor industrial. Ademais, os motores de indução são responsáveis pelo consumo aproximado de 46% da energia global (WAIDE; BRUNNER, 2011).

Com o objetivo de aumentar a produtividade e reduzir os custos, as indústrias buscam investir em inovações tecnológicas que aumentam o rendimento dos equipamentos muito usados em seu cenário. Com isso, a utilização de ferramentas que contribuem para o aperfeiçoamento desses equipamentos pode colaborar positivamente em seus desempenhos. Na perspectiva apresentada, parte considerável da evolução dos equipamentos usados atualmente, deve-se, principalmente, ao fato dos avanços obtidos na área das pesquisas científicas e do desenvolvimento de novas tecnologias. Isso porque as contribuições advindas das pesquisas, exercem um papel importante para a economia e, sobretudo, possibilitam a criação de máquinas mais eficientes e com bom desempenho.

Cumprе ressaltar que é cada vez mais frequente a utilização de ferramentas de Inteligência Computacional (IC) para identificação de sistemas dinâmicos. Acompanhando o processo histórico, percebe-se que as ferramentas de Inteligência Artificial (IA) eram utilizadas apenas por militares e, em grande medida, eram vistas somente em obras de ficção científica, simulando a existência e materialização de robôs futuristas que imitavam os comportamentos humanos (FUSARO et al., 2018). No entanto, atualmente, como afirma Frizzo (2020), é comum a utilização de ferramentas computacionais em sistemas

que requerem tomadas de decisões e que imitam aspectos da inteligência humana.

A inteligência artificial é uma área da ciência que tem como objetivo desenvolver tecnologias que possam realizar tarefas que geralmente requerem inteligência humana, como a capacidade de aprender, raciocinar e resolver problemas. A IA está transformando uma parcela cada vez mais significativa da sociedade e é mais visível a cada dia. Sistema de localização, *stream*, *boots* inteligentes em canais de atendimento, redes sociais, smartphones e o mais recente Chat GPT são apenas alguns exemplos que se pode notar sua influência (CARDOSO et al., 2023). Ainda sobre as influências da IA, é válido citar a recente greve dos atores e roteiristas de *Hollywood* iniciada em maio de 2023, no qual um dos pontos questionados pelos grevistas é a utilização de IA na elaboração de roteiros e em outros aspectos das produções (FERREIRA, 2023).

Este projeto apresenta uma análise de trabalhos recentes que mostram a eficácia da aplicação de RNA para a caracterização de sistemas dinâmicos. Assim, a revisão bibliográfica traz os resultados e as discussões referentes a temática desenvolvida. Com o objetivo de aplicar Redes Neurais Artificiais para o controle de carga em motor de indução, dividiu-se este estudo para apresentar a bancada de simulação desenvolvida por Soares (2017), mostrando a dinâmica dos resultados do trabalho.

A fim de estudar o comportamento do motor de indução a um sistema de simulação de cargas, Soares (2017) desenvolveu uma bancada didática, onde é realizada simulações de carga a partir de um sistema de frenagem eletromagnético. Este sistema apresentou um comportamento não-linear na resposta do motor em relação aos sinais de entrada. O sistema criado por Soares (2017) motivou a investigação a respeito da característica dinâmica, visto que obter resposta linear em função uma dada entrada é uma propriedade extremamente desejável, permitindo uma maior precisão no funcionamento. Vale destacar, inicialmente, que a função de uma rede neural artificial é aprender com treinamento, a partir da apresentação dos dados, um sistema que represente a saída em função das suas entradas (ROSA et al., 2017).

Nesse sentido, o presente trabalho propõe a aplicação de RNA para contornar a característica dinâmica apresentada na bancada desenvolvida por Soares (2017) e o treinamento será da RNA implementado através de algoritmo do *software Matrix Laboratory* (MATLAB)<sup>®</sup>. Os processos metodológicos foram desenvolvidos para mostrar os passos a serem tomados para a aplicação da IA no controle de carga no motor de indução com o intuito de que a rede aprenda a dinâmica do sistema não-linear representado pela bancada.

No campo da Engenharia Elétrica e Eletrônica, muitas aplicações empregam RNA, segundo Hernandez (2005). Pode se destacar entre as áreas de implementação de RNA, a produção de sistemas de controle adaptativo, a aplicação de classificadores e reconhe-

cedores de padrões, solução de problemas de otimização e a execução de sistemas de armazenamento e recuperação das informações (FRIZZO, 2020).

Pode-se citar como algumas das aplicações clássicas na Engenharia Elétrica a visão artificial e robótica, a interface humano-máquina naturais, o reconhecimento por síntese de voz, a modelagem e a identificação de sistemas não-lineares multivariáveis, entre outros. Pelo exposto, percebe-se a importância da utilização e, principalmente, no uso da RNA. Portanto, pretende-se, com o desenvolvimento desta pesquisa, contribuir para o conhecimento acerca da caracterização de sistemas dinâmicos, fazendo aplicação da RNA em sistema de cargas no motor de indução.

## 1.1 OBJETIVO GERAL

Aplicar as Redes Neurais Artificiais para a caracterização dinâmica de um sistema de controle de cargas para motores de indução.

## 1.2 OBJETIVOS ESPECÍFICOS

Com ênfase no objetivo principal proposto, foram determinados os seguintes objetivos específicos:

- Estudar trabalhos referentes a controle de carga e motores de indução;
- Estudar bibliografia no que diz respeito às Redes Neurais Artificiais;
- Gerar uma base de dados para o treinamento e implementação do algoritmo;
- Análise dos dados de estímulos de frenagem e velocidade do motor;
- Realizar treinamentos e testes da RNA por meio do *Software* MATLAB®;
- Produzir uma monografia com a descrição do desenvolvimento e análise dos resultados obtidos no trabalho.

## 1.3 JUSTIFICATIVA

Os motores de indução são amplamente utilizados nas indústrias e, conseqüentemente, suas aplicações são inúmeras, por isso, torna-se imprescindível o desenvolvimento de novas tecnologias que melhorem a performance, rendimento, bem como outras características associadas a essas máquinas. Para tanto, a definição de um modelo matemático

é importante para a performance de um controlador (ROSA et al., 2017), haja vista que mapear o sistema em busca da relação de entrada e saída permitirá um controle ajustado do comportamento do equipamento.

Soares (2017) desenvolveu uma bancada de simulação a fim de estudar o comportamento da resposta de motores de indução a perfis de variação de cargas bem definidos. Um sistema de freio eletromagnético simula a carga aplicada a um motor, e os sinais aplicados ao sistema de frenagem tinham forma de ondas de sinais elementares, tais quais como os do tipo senoide, rampa e degrau. Ao comparar as respostas do motor de indução na forma de velocidade angular para esses sinais de estímulo de carga, observou-se que a velocidade do motor não apresentou-se de forma linear. Tal comportamento, motivou uma investigação e, com isso, este trabalho tem o propósito de aplicar RNA com a finalidade de que ela aprenda o funcionamento do sistema da bancada para contornar essa característica dinâmica.

Ao realizar o estudo do perfil de variação de carga do sistema criado por Soares (2017), espera-se determinar quais os sinais de entrada são correspondentes a um comportamento desejado, solucionando assim, o problema da não-linearidade da bancada. Será obtido um sistema que fará as compensações necessárias para a linearização do mesmo, assim, as propriedades dos sinais de entradas serão mantidas nos sinais de saída, isto é, as características do sinal de entrada serão replicadas na resposta do sistema.

A partir disso, tem-se o entendimento de que com o perfil de variação de carga de qualquer sistema, será possível reproduzir tão bem quanto possível na saída, o sinal injetado na entrada. Isso trás inúmeras possibilidades de aplicações que contribuem para o desenvolvimento do estudo de máquinas elétricas, dentre as contribuições, pode-se citar, a caracterização de um sistema a partir de uma RNA que permitirá realizar simulações em laboratório, prever comportamentos de sistemas, compartilhar e dividir estudos de equipamentos com pesquisadores de diferentes lugares, dentre outras. Estas possibilidades indicam a relevância deste trabalho, que tem como objetivo a aplicação de RNA a fim de obter respostas lineares do sistema de simulação de cargas em motores de indução para os sinais injetados na entrada.

## 1.4 ORGANIZAÇÃO DO TEXTO

Este trabalho está organizado em 06 (seis) capítulos, no qual encontra-se com a seguinte estrutura:

**Capítulo 2** - É apresentada a revisão bibliográfica de trabalhos relevantes ao tema desta proposta de monografia.

**Capítulo 3** - É realizada a fundamentação teórica de conhecimentos técnicos fundamentais para embasamento do trabalho.

**Capítulo 4** - São descritas as características e o funcionamento da bancada de simulação criada por Soares (2017), na qual motivou o desenvolvimento deste trabalho acerca do comportamento não-linear dos dados apresentados.

**Capítulo 5** - É exposta a descrição metodológica para a realização do trabalho.

**Capítulo 6** - A partir do apresentado no escopo da proposta e das referências de trabalhos com temáticas similares, são realizadas conclusões sobre os resultados.

---

## REVISÃO BIBLIOGRÁFICA

Demidenko et al. (2001) desenvolveram um protótipo para um sistema de controle de um motor de indução, cuja função é detectar a variação repentina de carga e reagir adequando os parâmetros de controle, possibilitando, conseqüentemente, evitar danos ao sistema. No trabalho desenvolvido, são usados sensores de Efeito *Hall*<sup>1</sup> para determinar a velocidade do motor e com um microcontrolador captar e processar os dados. Em vista disso, com a mudança de velocidade permite-se estimar a variação de carga sofrida pelo sistema. Por conseguinte, quando isso acontece, o sistema toma contra medidas para amenizar os impactos gerados.

Nesta mesma linha de argumentação, um sistema de controle foi proposto pelos autores Bordon, Franchin e Castanho (2004) que apresentam, em seus estudos, uma estratégia de controle de motores de indução, permitindo o ajuste dinâmico de velocidade de um motor de indução, através do controle de frequência de rotação do motor em tempo real, e assegura que a corrente de entrada não ultrapasse o limite estipulado. Trata-se de “um controlador neuro nebuloso que combina a lógica nebulosa, atuando como ferramenta de inferência e as redes neurais artificiais, operando como ferramenta de agregação de dados” (BORDON; FRANCHIN; CASTANHO, 2004). Identifica-se, por meio dos resultados práticos apresentados no estudo, que a combinação de tais ferramentas resultam em um dispositivo capaz de controlar sistemas com características lineares ou não lineares, propiciando alto grau de desempenho e eficiência.

Ainda em consonância com as ideias apresentadas, Mazhari, Vahedi e Masoum (2007) propuseram um gerador de carga controlado por torque direto, do inglês, *Direct Torque Controlled* (DTC), baseado na modulação do vetor espacial. Para perceberem o

---

<sup>1</sup>Um Sensor de efeito Hall é um transdutor que, quando sob a aplicação de um campo magnético, responde com uma variação em sua tensão de saída.

desempenho do sistema, os autores analisaram e aplicaram o DTC clássico para modelar o dinamômetro. Através de simulações de diferentes partes do sistema, para o desenvolvimento do gerador proposto, utilizaram o SIMULINK, uma ferramenta computacional para modelagem, simulação e análise de sistemas dinâmicos entre outras funcionalidades contida no *software* MATLAB®. Com isso, foi possível investigar o desempenho do dinamômetro para vários perfis de cargas industriais. O trabalho de Mazhari, Vahedi e Masoum (2007) alcançou uma precisão de 95%. Além disso, obtiveram-se outras vantagens ao utilizar DTC convencional como resposta rápida, menor complexidade e menor corrente de acionamento.

Soares (2017) desenvolveu uma bancada didática a fim de estudar o comportamento do motor de indução com freio magnético acoplado, possibilitando a execução de simulações de cargas personalizadas. O sistema funciona com base em um freio eletromagnético para acoplamento ao motor e uma Unidade de Controle responsável por simular diversos tipos de cargas mecânicas. A Unidade de Controle cria e aplica ao sistema de freio sinais característicos como senoides, rampas e degraus através da Modulação por Largura de Pulso, do inglês *Pulse-Width Modulation* (PWM), e a velocidade angular do motor é obtida através de um sensor RPM.

Para a simulação de carga, o estímulo de frenagem aplicado para frear o motor, corresponde ao valor em percentual de *duty cycle* do sinal PWM gerado pela Unidade de Controle. Dessa forma a carga no motor pode variar entre 0% e 100%, mas para não ultrapassar a carga nominal permitida pelo fabricante do motor, o valor de *duty cycle* foi limitado em 60%. Ao simular os perfis de cargas, observou-se uma não correspondência linear, isto é, para variações do estímulo de carga próximas a 0% não obteve-se diminuição significativa da velocidade angular do motor, mas para as mesmas variações próximas a 60% a diminuição foi consideravelmente maior. Esses dados evidenciam uma não-linearidade do sistema (SOARES, 2017).

Com base nos resultados dos estudos de Soares (2017), é possível afirmar que o sinal de saída, não se comporta de maneira linear quando se comparado ao sinal de entrada, após realizar simulações em seu sistema. A partir do exposto, têm-se os propósitos iniciais para a elaboração e o desenvolvimento deste trabalho, objetivando a aplicação de técnicas não-lineares para identificação do comportamento dinâmico apresentado pelo sistema.

Por sua vez, o trabalho de Frizzo (2020) se dedica a aplicação de Redes Neurais Artificiais (RNA) na identificação de sistemas não-lineares. Na ocasião, o autor realizou análise de caso referente ao sistema não-linear dinâmico representado por um MIT. Com a finalidade de identificar a dinâmica de funcionamento do MIT, os resultados do estudo em questão demonstraram o treinamento realizado ao utilizar as quatro Redes Neurais Artificiais projetadas que atingiram os objetivos pré-determinados, alcançando o critério de parada, erro mínimo tolerado, pré-estabelecido de  $1 \times 10^{-10}$  em relação aos dados de

tensão de eixo direto do MIT.

No âmbito da Inteligência Artificial, apesar de não ser uma tecnologia idealizada há pouco tempo, vem surgindo alguns questionamentos devido a sua rápida difusão recente. Ferreira, Garcia e Brasil (2023) expõem uma preocupação relevante no trabalho intitulado de “O surgimento do Chat GPT e a insegurança sobre o futuro dos trabalhos acadêmicos”, uma vez que essa ferramenta se popularizou na criação de trabalhos escolares e acadêmicos.

O Chat GPT é mais uma ferramenta de IA em desenvolvimento na atualidade, apesar de ainda está em fase de testes, apresenta grande potencial em suas aplicações, e no quesito “banco de dados” superou até então modelos de IA como as assistentes pessoais Siri (Apple) e Alexa (Amazon). A própria IA externaliza sua habilidade como:

O Chat GPT é capaz de processar e gerar respostas de linguagem natural em uma ampla gama de idiomas e dialetos, de se adaptar ao tom e estilo das consultas que recebem. Além disso, sua impressionante capacidade de processar grandes quantidades de dados o converte em uma ferramenta inestimável para aqueles que buscam extrair conhecimento de grandes conjuntos de dados (trad. livre) (CASTELLS, 2023).

Questionamentos levantados desde a revolução industrial, tornam a preocupar algumas áreas atualmente, como a substituição de profissionais por máquinas e equipamentos tão ou mais eficientes quanto. No caso da inteligência artificial, o questionamento é se uma máquina é capaz de processar informações de forma semelhante ao cérebro humano, ou ainda se passar por um, sendo capaz de aprender e aperfeiçoar suas habilidades. Os pesquisadores Ferreira, Garcia e Brasil (2023) reconhecem que essa tecnologia é bastante eficiente, mas receia que a qualidade de ensino seja prejudicada devido à facilidade que esta proporciona a alunos que buscam atalhos através desta ferramenta, sugerindo até uma mudança na forma de avaliação, uma vez que tentar restringir o avanço da tecnologia pode configurar um retrocesso.

A seguir, apresenta-se a fundamentação teórica do estudo, especificando o embasamento que será seguido para a concretização prática da pesquisa.

---

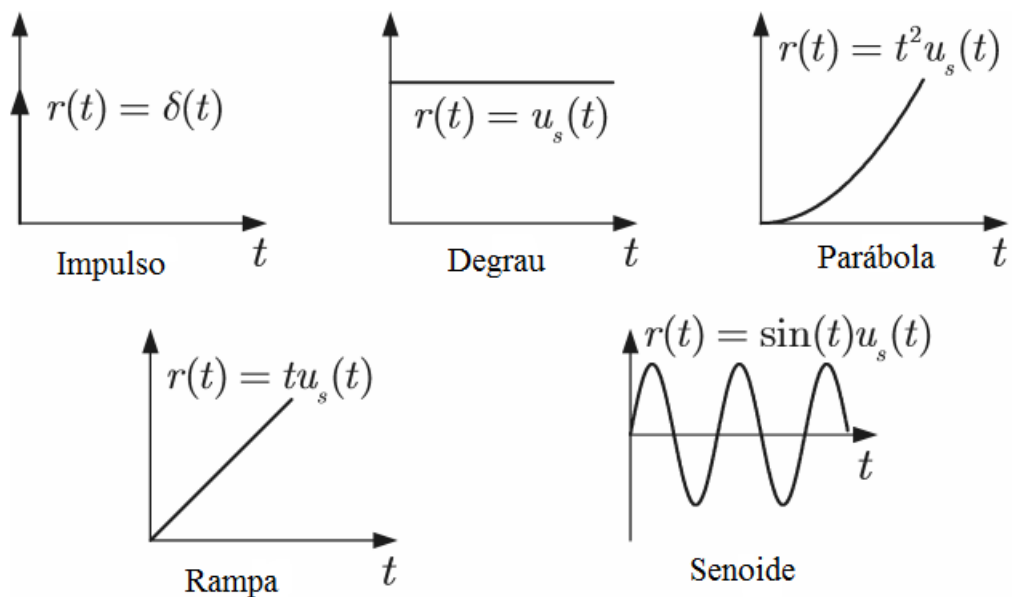
## FUNDAMENTAÇÃO TEÓRICA

### 3.1 SINAIS ELEMENTARES

Os sinais, de uma forma ou de outra constituem um ingrediente básico da nossa vida diária. Eles são a base da comunicação, como pela fala, textos, imagens, internet assim como outras (HAYKIN; VEEN, 2001). No âmbito da engenharia, a transmissão e o processamento de sinais tornam possível o funcionamento de todo o sistema elétrico e de dados. Em projetos de controle, são usados sinais elementares (impulso, degrau, rampa, parábola e senoide) para analisar o desempenho do sistema, alguns sinais básicos são descritos a seguir.

A definição do sinal impulso é que tem amplitude infinita no instante  $t=0$ , e amplitude 0 nos demais instantes (NISE; SILVA, 2002). Obviamente, esse sinal não existe na prática, mas uma aproximação é usada para aplicar energia inicial ao sistema e obter a resposta transitória. Esse sinal geralmente é utilizado para obter modelos matemáticos de sistemas lineares. As senoides também podem ser usadas para testar sistemas físicos e obter modelos matemático, além de compor grande parte dos sinais de estudo. O sinal em degrau representa uma entrada constante, normalmente, apresenta a mesma forma na saída em sistemas lineares. Diferentemente do sinal em rampa, que representa um comando linearmente crescente (NISE; SILVA, 2002). Na Figura 1 pode ser observada as formas de ondas e as descrições matemáticas dos sinais citados.

Figura 1 – Sinais elementares




Fonte: Próprio autor

## 3.2 SINAL PWM

O sinal de Modulação por Largura de Pulso, do inglês *Pulse Width Modulation* - PWM é uma técnica para controlar a potência de equipamentos elétricos, regulando a tensão média na saída de acordo a variação da largura de pulso, a exemplo controle de velocidade de motores *Direct Current* (DC), do controle de luminosidade, fontes chaveadas e de servo motores.

O sinal PWM consiste no constante chaveamento de uma onda quadrada, isso é, liga e desliga várias vezes durante o ciclo (alta frequência). A potência entregue a carga depende do percentual do tempo de cada ciclo em que a o chaveamento permanece fechado, se a chave de gatilho permanecer 60% do tempo ativada, a potência entregue ao equipamento será de 60%, em outras palavras, a tensão média da carga é proporcional ao tempo em que o pulso do sinal PWM se mantem em nível lógico alto no período (*Duty Cycle*). Os sinais de gatilho são gerados a partir da comparação entre dois sinais, o de referência (geralmente triangular) e o da portadora (CC), Conforme se observa na Figura 2. Os harmônicos gerados devido aos chaveamentos em altas frequências podem ser facilmente filtrados (RASHID et al., 1999).

Figura 2 – Sinal PWM



Fonte: (RASHID et al., 1999)

O sinal efetivo da largura de pulso expresso em percentual é denominado *Duty Cycle*, equivale da razão entre o tempo onde a chave permanece em nível lógico alto e o tempo total do período, de acordo com a Equação 1.

$$DC(\%) = 100 \times \frac{LP}{T} \quad (1)$$

Onde:

$DC$  corresponde ao *duty cycle* do PWM em percentual;

$LP$  a largura de pulso;

$T$  ao período.

### 3.3 MOTORES DE INDUÇÃO TRIFÁSICOS

Na vida moderna, os motores de indução estão presentes em praticamente todos os lugares. Em nossas casas, eles são responsáveis por acionar refrigeradores, freezers, aspiradores de pó, processadores de alimentos, aparelhos de ar condicionado, ventiladores e outros eletrodomésticos semelhantes. Nas indústrias, esses motores fornecem a força necessária para movimentar quase todas as máquinas (CHAPMAN, 2013).

A ampla utilização dos motores elétricos se deve ao fato de utilizarem energia elétrica, uma fonte limpa, eficiente, de fácil transmissão a longas distâncias e de simples controle. Além disso, os motores elétricos não necessitam de ventilação constante nem

de combustíveis derivados do petróleo. Por essas razões, são ideais para ambientes onde a emissão de poluentes gerados por combustão não é desejada (CHAPMAN, 2013). Na Figura 3 é ilustrado um motor de indução trifásico.

**Figura 3** – Motor de indução da marca WEG



Fonte: (WEG, 2005)

Um motor de indução possui fisicamente o mesmo estator que uma máquina síncrona, diferenciando-se na construção do rotor. Um estator típico de dois polos é ilustrado na Figura 4. Ele parece, e de fato é, igual ao estator de uma máquina síncrona. Existem dois tipos distintos de rotores que podem ser inseridos no interior do estator de um motor de indução: o rotor gaiola de esquilo e o rotor bobinado (CHAPMAN, 2013).

**Figura 4** – Estator típico de um motor de indução




Fonte: (CHAPMAN, 2013)

### 3.3.1 Motor de Indução com Rotor tipo Gaiola

A Figura 5 apresenta um rotor de motor de indução do tipo gaiola de esquilo. Esse rotor é composto por uma série de barras condutoras encaixadas em ranhuras na superfície do rotor, conectadas em curto-circuito em ambas as extremidades por grandes anéis de curto-circuito. Essa construção é chamada de rotor gaiola de esquilo porque, se os condutores fossem observados isoladamente, se assemelhariam às rodas usadas por esquilos ou hamsters para exercícios(CHAPMAN, 2013).


**Figura 5** – Típico rotor gaiola de esquilo



Fonte: (CHAPMAN, 2013)

### 3.3.2 Motor de Indução com Rotor tipo Bobinado

Um rotor bobinado possui um conjunto completo de enrolamentos trifásicos, semelhantes aos do estator. As três fases dos enrolamentos do rotor são geralmente conectadas em Y, com suas extremidades ligadas a anéis deslizantes no eixo do rotor. Os enrolamentos do rotor são colocados em curto-circuito por meio de escovas que fazem contato com os anéis deslizantes. Assim, nos motores de indução com rotor bobinado, as correntes do rotor podem ser acessadas através das escovas, permitindo que sejam examinadas ou que resistências adicionais sejam inseridas no circuito do rotor. Um motor de indução com rotor bobinado completo é mostrado na Figura 6.


**Figura 6** – Vista em corte de um motor de indução de rotor bobinado

Fonte: (CHAPMAN, 2013)

Os motores de indução com rotor bobinado possuem um custo mais elevado em comparação aos motores de indução com rotor gaiola de esquilo. Além disso, demandam mais manutenção devido ao desgaste das escovas e dos anéis deslizantes. Por esse motivo, os motores de indução com rotor bobinado são raramente utilizados (CHAPMAN, 2013).

### 3.3.3 Curva de velocidade *versus* torque

As características essenciais dos Motores de Indução Trifásicos (MIT) estão diretamente ligadas à curva que relaciona a velocidade com o torque do motor. Compreender essas propriedades é crucial para determinar suas possíveis aplicações. Entre o estator e o rotor, forma-se um campo magnético que se contrapõe ao campo girante, resultado das correntes induzidas que percorrem os condutores do rotor (CHAPMAN, 2013). É mostrado na Figura 7 o circuito equivalente de *Thevenin* do circuito do rotor.

**Figura 7** – Circuito equivalente de *Thevenin* do rotor

Fonte: (CHAPMAN, 2013)

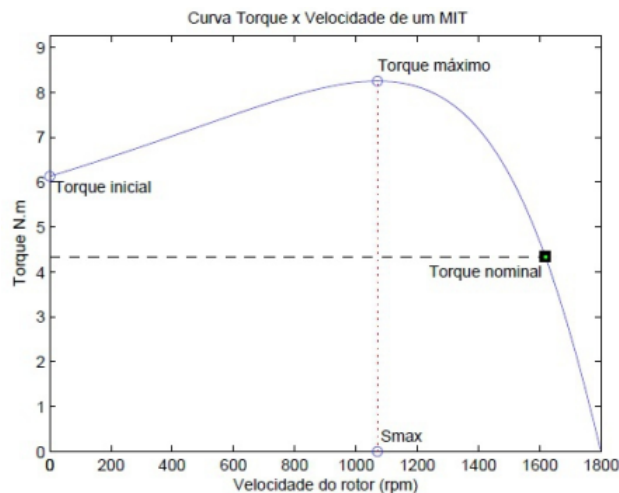
O torque é calculado a partir da Equação 2, onde,  $V_{TH}$ ,  $X_{TH}$ ,  $R_{TH}$  são equivalentes

de Thevenin,  $s$  é o escorregamento,  $X_2$  e  $r_2$  são os parâmetros do rotor (CHAPMAN, 2013).

$$\tau = \frac{3}{\omega_S} \frac{V_{th}^2 (r_2/s)}{(R_{th} + r_2/s)^2 + (X_{th} + X_2)^2} \quad (2)$$

A curva torque característica de um MIT é representada no gráfico disposto na Figura 8.

**Figura 8** – Curva característica do torque versus velocidade de um MIT



Fonte: (SILVA, 2014)

Os três pontos ressaltados no gráfico são:

Torque de partida ou inicial é o torque realizado pelo MIT com rotor bloqueado.

Torque máximo acontece quando o MIT atinge o seu maior valor de torque sob frequência e tensão nominal.

Torque nominal acontece quando o MIT desenvolve o torque submetido a: tensão, potência e frequências nominais.


## 3.4 REDES NEURAIS ARTIFICIAIS

### 3.4.1 Neurônio Artificial

Uma das definições de Redes Neurais Artificiais (RNAs) são sistemas computacionais que processam informações com base no funcionamento do cérebro e nas conexões de seus neurônios. O neurônio é uma unidade de processamento de informação fundamental para operação de uma rede neural. Através do processo de aprendizagem, a RNA adquire conhecimento e o armazena na forma de pesos sinápticos (HAYKIN, 1999). Na Figura

9 pode ser observado um modelo de neurônio artificial proposto por McCulloch e Pitts (1943).

**Figura 9** – Neurônio artificial



Fonte: (HAYKIN, 1999) (modificado)

Neste modelo de neurônio, as sinaps ( $w_{kj}$ ) são representadas por pesos associadas a cada entrada do neurônio ( $x_j$ ), uma função somadora, como o próprio nome já diz, soma essas associações. A função de ativação limita os valores de saída do neurônio para valores finitos, as bias ( $b_k$ ) tem a função de aumentar ou diminuir o valor da função de ativação. A Equação 3 descreve matematicamente o neurônio artificial.

$$y_k = f(u_k) = f\left(\sum_{j=1}^m w_{kj}x_j + b_k\right) \quad (3)$$

Onde os termos da Equação 3 são descritos a seguir:

- $y_k$  - é a saída produzida pelo neurônio artificial;
- $f(u_k)$  - função de ativação;
- $w_{kj}$  - pesos associados as entrada;
- $x_j$  - valores de entrada;
- $b_k$  - constante da equação que ajusta a função.

### 3.4.2 Função de Ativação

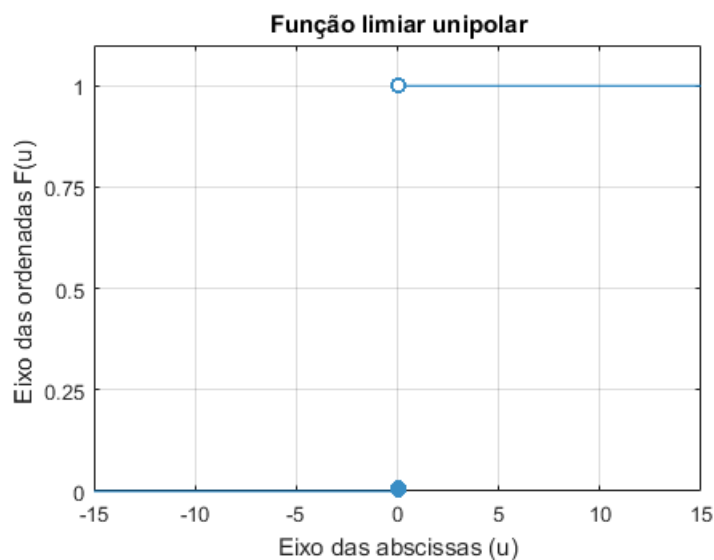
Normalmente, a função de ativação  $f(u_k)$  é não-linear e tem o objetivo de limitar a amplitude da saída de um neurônio (FIORI, 2007). É uma expressão matemática que se aplica à soma ponderada das entradas e dos pesos, com a finalidade de estabelecer a relação entre as entradas e saídas de cada neurônio na Rede Neural (MIRANDA, 2017). As funções comumente usadas para introduzir não-linearidades serão explicadas a seguir.

#### 3.1.2.1 Função Limiar Unipolar

Essa propriedade se refere ao caso em que a saída de um neurônio se torna ativa, ou seja, assume o valor 1 (um), quando a combinação ponderada dos sinais de entrada ultrapassa um certo limiar  $u$  (valor positivo). Quando o valor de ativação é nulo ou negativo, a saída do neurônio é zero. Essa dinâmica pode ser analisada de forma matemática através da Equação 4 e visualmente na representação gráfica apresentada na Figura 10 (KOTLINSKI, 2013).

$$f(u) = \begin{cases} 1, & \text{se } u > 0 \\ 0, & \text{se } u \leq 0 \end{cases} \quad (4)$$

**Figura 10** – Representação da função limiar unipolar



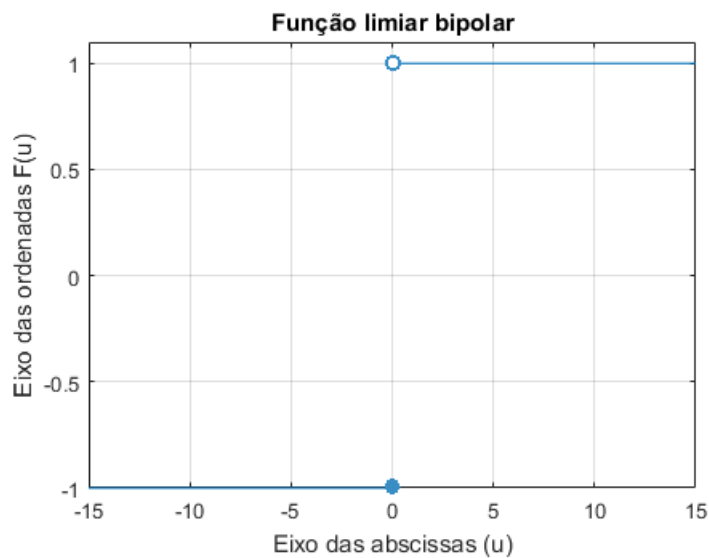
Fonte: Próprio autor

### 3.3.2.2 Função Limiar Bipolar

Neste caso, a saída do neurônio assume valor 1 se a soma ponderada dos sinais de entrada exceder a um determinado limiar  $u$  (valor positivo). A saída assumirá valor de -1 quando o valor de ativação adotar valor nulo ou negativo. O comportamento neste caso pode ser visto matematicamente pela Equação 5 e graficamente na representação da Figura 11 (KOTLINSKI, 2013).

$$f(u) = \begin{cases} 1, & \text{se } u > 0 \\ -1, & \text{se } u \leq 0 \end{cases} \quad (5)$$

**Figura 11** – Representação da Função Limiar Bipolar



Fonte: Próprio autor

### 3.3.2.3 Função Sigmóide

Esta função admite que o valor de saída do neurônio assumira valores em um intervalo contínuo de 0 a 1. Para construção de uma Rede Neural a função sigmóide tem grande importância pelo fato de sua capacidade de diferenciabilidade. A Equação 6 representa o comportamento da função matematicamente e pode-se observar a sua representação gráfica de acordo com a Figura 12 (FIORI, 2007).

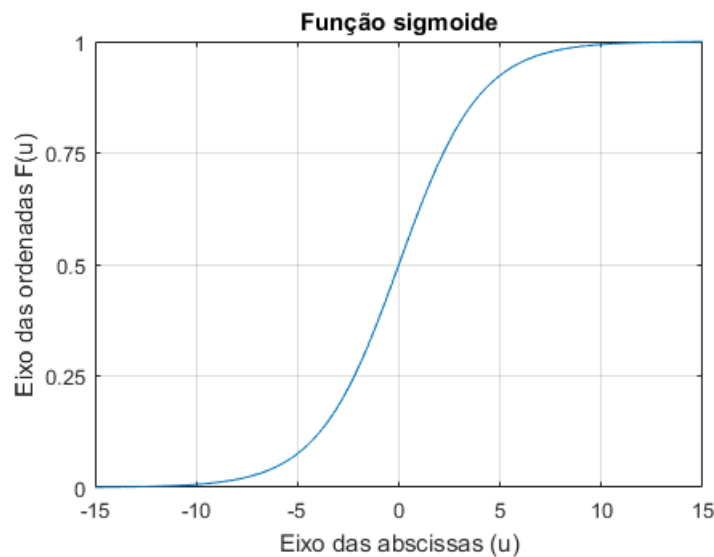
$$f(u) = \frac{1}{1+e^{-au}} \quad (6)$$

Onde:

$u$  – é a ativação;

$a$  – é o parâmetro de inclinação da função sigmóide.

**Figura 12** – Representação gráfica da Função Sigmóide



Fonte: Próprio autor

Obs.: À medida que o parâmetro é aumentado, aproximando-se do infinito, essa função passa a se comportar como uma função limiar.

### 3.3.2.4 Função Tangente Hiperbólica

Nesta função, a inclinação da curva é controlada pelo parâmetro " $a$ ", enquanto os limites inferior e superior são determinados pelo parâmetro " $b$ ". Isso significa que é viável ajustar a saída do neurônio conforme as características da função. No gráfico apresentado na Figura 13, a função de ativação do neurônio (Equação 7) varia de forma contínua entre -1 e 1 (KOTLINSKI, 2013).

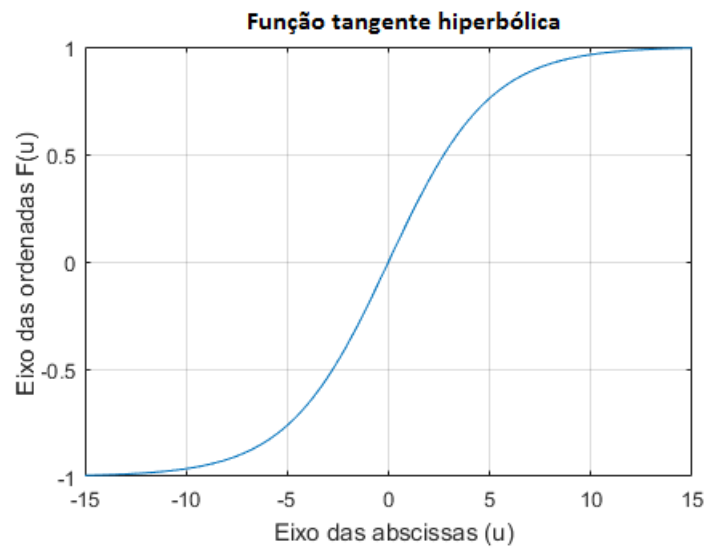
$$f(u) = b \cdot \frac{e^{au} - e^{-au}}{e^{au} + e^{-au}} \quad (7)$$

Onde:

$a$  – é o parâmetro de inclinação da curva;

$b$  – os limites inferiores e superiores;

$u$  – é a ativação.

**Figura 13** – Representação gráfica da função tangente hiperbólica

Fonte: Próprio autor

### 3.4.3 Arquitetura de Redes Neurais Artificiais


A estrutura dos neurônios em uma Rede Neural está intimamente relacionada com o algoritmo de aprendizagem utilizado. Esses algoritmos, também chamados de regras de aprendizagem, desempenham um papel fundamental no projeto das Redes Neurais (HAYKIN, 2001). Em algumas arquiteturas, os neurônios são organizados em uma ou mais camadas, onde os neurônios de uma mesma camada geralmente compartilham a mesma função de ativação e padrão de interconexões. A camada de entrada, por não realizar cálculos, não é contabilizada ao determinar o número total de camadas da rede (KOTLINSKI, 2013).

É possível desenvolver uma variedade de arquiteturas de Redes Neurais Artificiais, considerando diferentes aspectos, como o modelo de neurônio, as funções de ativação, a estrutura da rede e os elementos de recorrência (KOTLINSKI, 2013). A maneira como os neurônios se conectam determina o tipo de arquitetura da rede. Geralmente, existem várias arquiteturas de Redes Neurais Artificiais. No entanto, considerando o número de camadas de neurônios e a forma como estão interconectados, pode-se destacar algumas classes mais comuns de arquiteturas de Redes Neurais mencionadas na literatura (HAYKIN, 2001).

### 3.3.3.1 Redes *Feedforward* de Camada Única

Nessa forma mais básica de Rede Neural em camadas, existe apenas uma camada de entrada de nós de entrada, que se projeta em uma única camada de saída de neurônios (nós computacionais), mas não vice-versa. Essa rede é caracterizada por ser estritamente de propagação direta ou acíclica, o que significa que não há *loops* de realimentação. Essa arquitetura pode ser observada na Figura 14, onde também se pode notar que os pesos sinápticos estão implícitos nas conexões entre as camadas (HAYKIN, 2001).

Figura 14 – Rede *Feedforward* de Camada Única



Fonte: Adaptado de (KOTLINSKI, 2013)

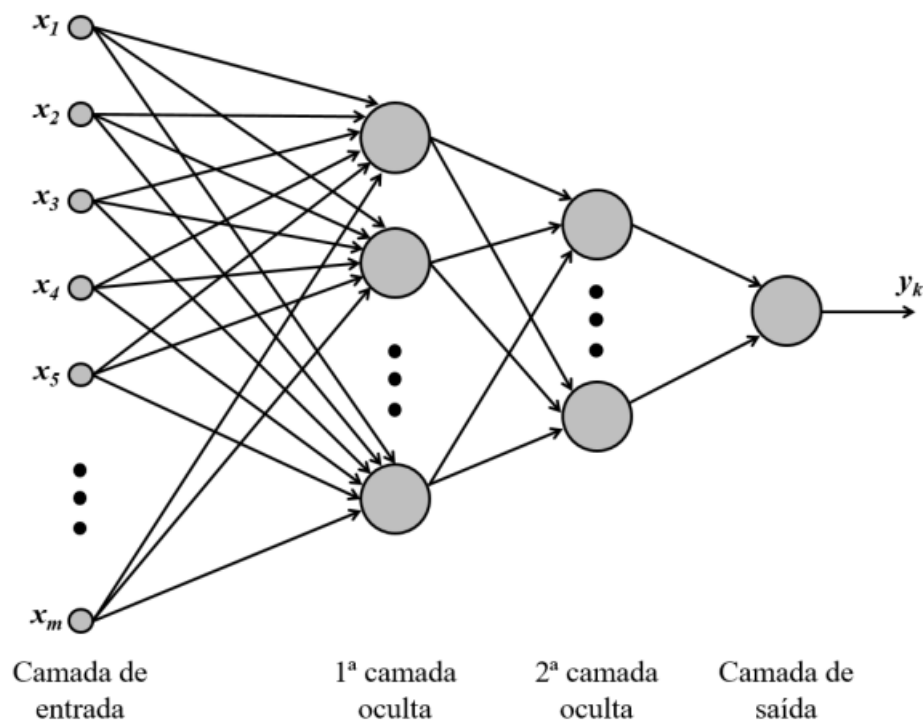
### 3.3.3.2 Redes *Feedforward* de Múltiplas Camadas

De acordo com Haykin (2001), nesta categoria de Rede Neural *Feedforward*, há a presença de uma ou mais camadas ocultas, também conhecidas como camadas intermediárias, onde os nós de processamento são chamados de neurônios ocultos ou unidades ocultas. A inclusão de uma ou mais camadas ocultas permite que a rede extraia estatísticas de ordem mais elevada. Além disso, a rede adquire uma perspectiva global, apesar de manter uma conectividade local, devido à presença de um conjunto adicional de conexões sinápticas e uma dimensão extra de iterações neurais.

Os nós de origem da camada de entrada fornecem os elementos do padrão de ativação, que servem como sinais de entrada para os neurônios na segunda camada, conhecida como a primeira camada oculta. Os sinais produzidos por esta segunda camada são então utilizados como entrada para a terceira camada de neurônios, e assim sucessivamente para as camadas subsequentes da Rede Neural. A resposta global da rede é formada pelos sinais de saída dos neurônios na camada final, que são influenciados pelo padrão de ativação dos nós de origem na camada de entrada.

Essa estrutura de rede está representada na Figura 15, onde, assim como na Figura 14 (representando uma camada única), as redes são consideradas totalmente conectadas. Isso se deve ao fato de que os nós de uma camada estão interligados a todos os nós da camada seguinte. Por outro lado, redes parcialmente conectadas não apresentam essa característica.

**Figura 15** – Redes *Feedforward* de Múltiplas Camadas




Fonte: Adaptado de (KOTLINSKI, 2013)

### 3.3.3.3 Redes Recorrentes (*Feedback*)

As Redes Neurais recorrentes se distinguem das Redes Neurais *Feedforward* pelo fato de incluírem pelo menos um laço de realimentação. Uma rede recorrente pode consistir em uma única camada de neurônios, onde cada neurônio envia seu sinal de saída de volta para as entradas de todos os outros. Outra classe de redes recorrentes inclui neurônios ocultos. Na Figura 16 é possível visualizar uma rede com essa arquitetura, apresentando um neurônio oculto (em cinza) e dois neurônios de saída. Os modelos mais comuns de redes *Feedback* são os de Elman e Hopfield (HAYKIN, 2001).

**Figura 16** – Rede Neural *Feedback*




Fonte: Adaptado de (KOTLINSKI, 2013)

---

## BANCADA DE SIMULAÇÃO

A obtenção de aspectos relacionados a motores de indução é possível graças a experimentos realizados com o mesmo. Tais experimentos nem sempre são factíveis devido as condições em que geralmente essas máquinas são instaladas, pois existem riscos de acidente e em alguns casos o ambiente é insalubre (SILVA et al., 2000). Motivado a contribuir para o estudo de máquinas elétricas, Soares (2017) desenvolveu uma banca de simulação didática para analisar o comportamento do motor de indução a um sistema de cargas em ambiente laboratorial, onde o freio magnético simula cargas aplicado ao motor a partir de estímulos característicos criado em *software* independente. A bancada pode ser observada na Figura 17.

**Figura 17** – Bancada de simulação



Fonte: (SOARES, 2017)

Este trabalho investiga o comportamento dinâmico apresentado pelo motor de indução por meio dos sinais de velocidade, quando este foi submetido a simulações de carga através de freios eletromagnéticos no trabalho desenvolvido por Soares (2017). Dessa forma, a seguir, são descritos alguns componentes que integram a bancada desenvolvida por ele e seu funcionamento.

## 4.1 MOTOR DA BANCADA

O motor de indução monofásico utilizado na bancada montada por Soares (2017) é um motor antigo e muitas das informações técnicas já se perderam devido aos desgastes sofridos por ele com o passar do tempo. Os motores industriais são na sua maioria trifásicos, pois possuem um maior rendimento e um menor volume se comparados aos monofásicos de mesma potência. À vista disso, foi realizada a substituição do motor monofásico por um trifásico, trazendo um aspecto de modernidade à bancada, uma vez que abre um leque de possibilidades para trabalhos futuros.

O motor trifásico (380 V) utilizado na bancada de simulação para este trabalho é da marca HERCULES e pode ser observado na Figura 18.

**Figura 18** – Motor da Bancada



Fonte: Próprio autor

O motor em questão possui potência de 1/2 cv, a frequência de rede é 60 Hz, com velocidade nominal de 1685 RPM. No Quadro 1 encontra-se as suas características

técnicas.

**Quadro 1** – Informações técnicas do motor de indução

Grandezas	Valores nominais
Nº de fases	3
Potência	1/2 cv ou 0.37 kW
Tensão	380 V
Corrente elétrica	1.07 A
Corrente de partida	5.35 A
Velocidade	1685 RPM
Frequência	60 Hz
Fator de potência	0.70

## 4.2 UNIDADE DE CONTROLE

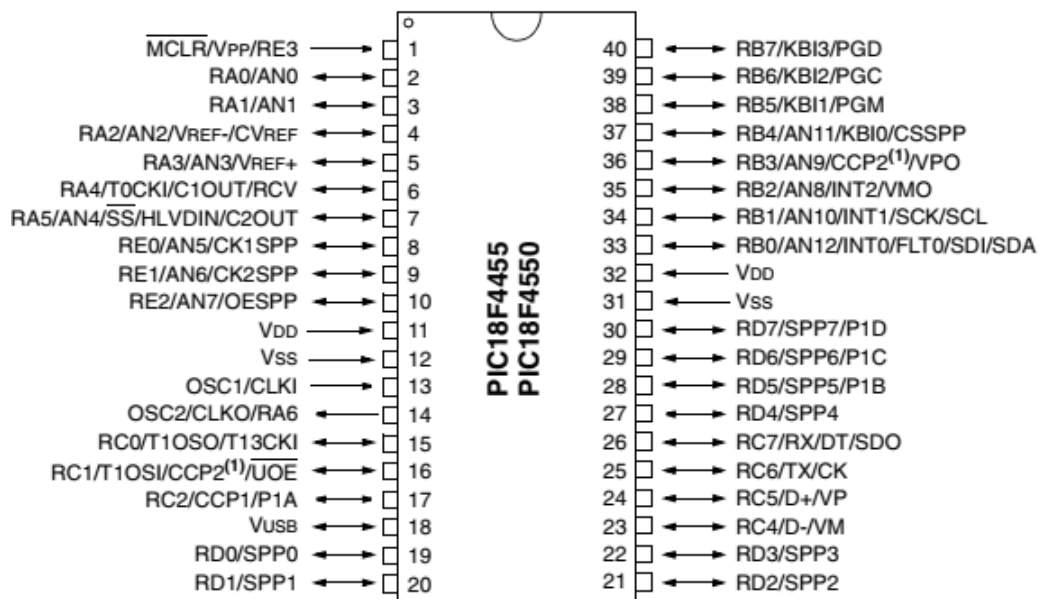
Foi desenvolvida por Soares (2017) uma Unidade de Controle para coordenar a bancada de simulação, sendo ela é responsável por aplicar os sinais que gerenciam o sistema de frenagem, com uma interface que o usuário pudesse executar comandos. Usando de um microcontrolador, dispositivo capaz de realizar processamento de dados através de suas entradas/saídas e memória, executam-se funções básicas de controle. Existe uma grande variedade de microcontroladores com diferentes especificações para as mais variadas aplicações, alguns desses microcontroladores são produzidos pela Microchip Technology Inc., os *Programmable Intelligent Computer* (PIC) são Circuitos Integrados (CI) na categoria de microcontroladores capazes de serem programados para realizar diversas funções.

É essencial que a escolha do microcontrolador seja feita com bastante cuidado, devendo atender às necessidades do projeto e ser economicamente viável, visto que o custo de implementação também é importante. O PIC escolhido para integrar a Unidade de Comando foi o 18F4550, devido à quantidade de pinos disponíveis, a disponibilidade de conversores Analógico/Digital (A/D) e uma interface *Universal Serial Bus* (USB) para atualização do *firmware*, após a conclusão o protótipo (MICROCHIP, 2006). É mostrado na Figura 19 o PIC 18F4550 com a descrição dos seus pinos.

A Unidade de Controle é alimentada com 12 V de uma fonte externa, devido a um regulador de tensão LM 7805 que com essa fonte na entrada, proporciona uma tensão de 5 V com corrente de 1.5 A ao PIC, que são suficientes para o bom funcionamento da placa. É possível alterar a fonte de alimentação do circuito para a porta USB ou para a fonte externa através de um *jump* PW-SEL<sup>1</sup>. A placa possui as interfaces de ligações

<sup>1</sup>No âmbito da elétrica e eletrônica, *jumps* são terminais que interligam dois ou mais pontos de um circuito

Figura 19 – Pinos do PIC 18F4550




Fonte: (MICROCHIP, 2006)

dos periféricos como: Teclado, entrada de 8 bits de dados externos, *display* e o *In-Circuit Serial Programming* (ICSP) para ligação da gravadora do PIC. O circuito tem ainda uma placa com o sensor de corrente ACS712 capaz de medir correntes alternadas (*Alternating Current* - AC) de até 20 A. Este sensor possui a função de mensurar a corrente em uma das fases do motor de indução. A entrada USB permite uma gravação direta do *Personal Computer* (PC) ao PIC sem a necessidade de usar uma gravadora externa pelo usuário, esse processo é permitido quando o PIC está carregado com o *Bootloader*<sup>2</sup>, o que facilita a atualização do *firmware* (SOARES, 2017). Está disposta na Figura 20 a placa da Unidade de Controle com os componentes.

<sup>2</sup>O *Bootloader* é programa que permite a comunicação entre o computador e a memória do microcontrolador sem a necessidade de um gravador, com ele é possível ler, apagar e gravar novos dados na flash do PIC.

Figura 20 – Placa da Unidade de Controle



Fonte: (SOARES, 2017)

### 4.3 *DRIVE* DE POTÊNCIA

O sistema de frenagem demanda de uma energia que a unidade de controle é incapaz de fornecer, por isso, utilizou-se de uma fonte *DC* de 36 V que é capaz de fornecer uma corrente de até 4 A, haja vista que a corrente necessária para a alimentação da bobinas é de 3 A. Confere-se na Figura 21 a fonte DC para alimentação do *drive* de Potência.

Figura 21 – Fonte DC de 36 V



Fonte: (SOARES, 2017)

O *drive* de potência tem a função de acionar cargas maiores a partir de sinais de



a luz refletida pelo adesivo.

**Figura 23** – Adesivo reflexivo no *optor coupling*




Fonte: (SOARES, 2017)

Enquanto ocorre o movimento de rotação do eixo, a luz emitida pelo transmissor é refletida pelo adesivo reflexivo e captado pelo receptor do TCRT5000. O sinal gerado se aproxima de uma onda quadrada que varia sua frequência de acordo a velocidade do motor.

O sinal gerado pelo sensor de RPM é enviado para Unidade de Controle. A placa do sensor óptico TCRT5000 foi instalada em um suporte e fixado próximo ao *optor coupler* de forma que a distância do transmissor para o adesivo reflexivo seja aproximadamente 10 mm. É mostrado na Figura 24 a placa do sensor RPM concluída.

**Figura 24** – Placa do sensor RPM

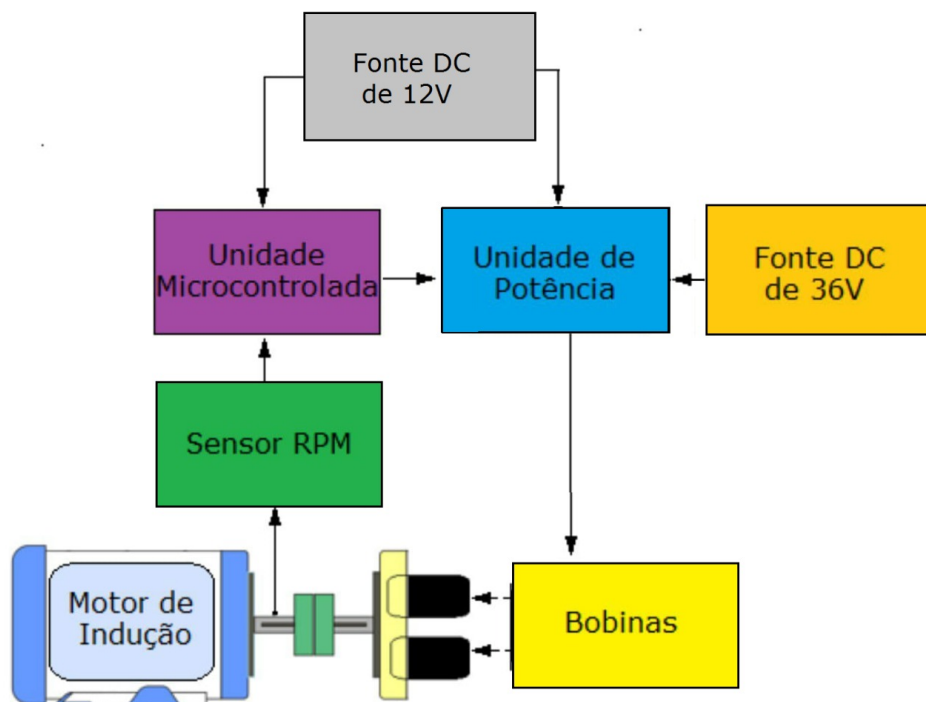


Fonte: (SOARES, 2017)

## 4.5 FUNCIONAMENTO DA BANCADA

A bancada de simulação é composta por alguns equipamentos que tornam possível o seu funcionamento. É expresso na Figura 25 um diagrama simples da montagem da bancada.

**Figura 25** – Diagrama de comunicação entre os principais componentes eletrônicos da bancada




Fonte: Próprio autor

O diagrama apresentado na Figura 26 mostra de forma simplificada, as conexões dos principais dispositivos eletrônicos que compõe a bancada. A fonte 12 V DC alimenta os circuitos de baixa potência (Unidade de Controle e *drive* de potência), e esses, por sua vez, possuem reguladores de tensão que estabiliza a tensão de entrada em 5 V. O sensor RPM (tacômetro)<sup>5</sup>, envia sinais de velocidade do motor ao microcontrolador 18F4550, que integrado à Unidade de Microcontrolada representa o “celebro” da bancada. Ela é responsável pelo processamento dos sinais de velocidade e criação e aplicação dos sinais de estímulos para o sistema de carga. O *drive* de potência é alimentado por uma fonte DC de 36 V capaz de fornecer até 4 A de corrente. Os sinais de PWM recebidos pelo *drive*, são transformados sinais de corrente que variam de 0 a 3 A, estes, são aplicados nas bobinas para a frenagem do motor.

<sup>5</sup>O tacômetro é um dispositivo que serve para fazer a medição da quantidade de rotações por minuto (RPM) de um determinado motor.

Figura 26 – Esquema de ligação



Fonte: (SOARES, 2017)

A bancada desenvolvida por Soares (2017) possui os seguintes componentes principais:

- Motor monofásico de 1/2 cv;
- Disco metálico circular;
- Duas bobinas eletromagnéticas com 1000 voltas de fio 17 *American Wire Gauge* (AWG);
- *Drive* de potência;
- Unidade de Controle.

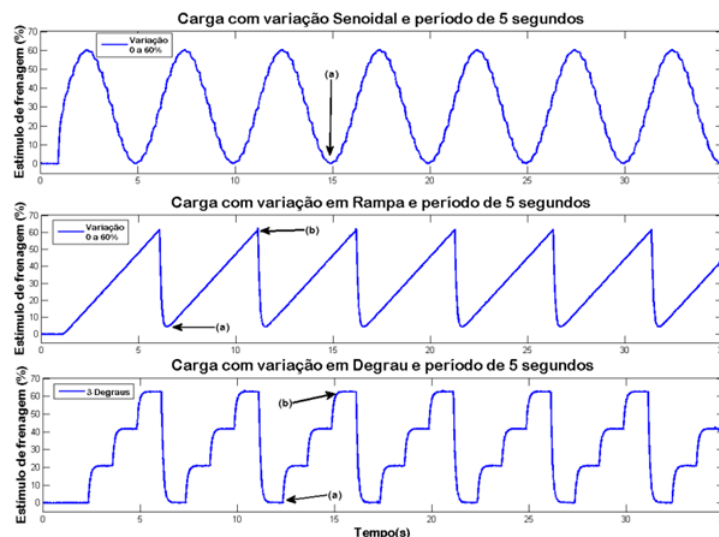
O motor de indução usado na bancada de Soares (2017) é da marca Porter de 1/2

CV, monofásico de 60 Hz, com velocidade síncrona de 1790 RPM aproximadamente. O sistema de frenagem é composto pelo disco metálico circular, as bobinas e o *Drive* de potência. Este recebe os sinais da unidade de comando e aplica nas bobinas variação de corrente de 0 até 3 A, permitindo ao sistema de simulação a frenagem no disco aclopado ao motor de indução.

Durante o movimento do disco, as correntes induzidas produzem uma força que se opõem ao movimento de rotação. A corrente que circula pelas bobinas está diretamente relacionada com a força do campo magnético gerado pelas mesmas. Dessa forma, a variação da corrente nas bobinas permite variar a frenagem do disco. O *Drive* de Potência faz o controle desta corrente através do sinal PWM recebido pela Unidade de Controle. O sinal PWM permite controlar a potência entregue a carga durante a variação de 0% a 100% do *duty cycle*.

A Unidade de Controle possui diferentes modos de operação, o MANUAL, onde o *duty cycle* pode ser ajustado manualmente através do *encoder*<sup>6</sup>. O EXTERNO, nesse modo pode-se inserir um sinal externo de 8 bits e, ainda o modo PERSONALIZADO com sinais pré definidos no sistema como RAMPA, DEGRAU e SENÓIDE, esses sinais são gerados por códigos através de funções independentes. Para conferência, na Figura 27 são exibidos alguns sinais usados por Soares (2017) na frenagem dos tipos SENOIDAL, RAMPA E DEGRAU respectivamente.

**Figura 27** – Sinais de frenagem



Fonte: (SOARES, 2017) (modificado)

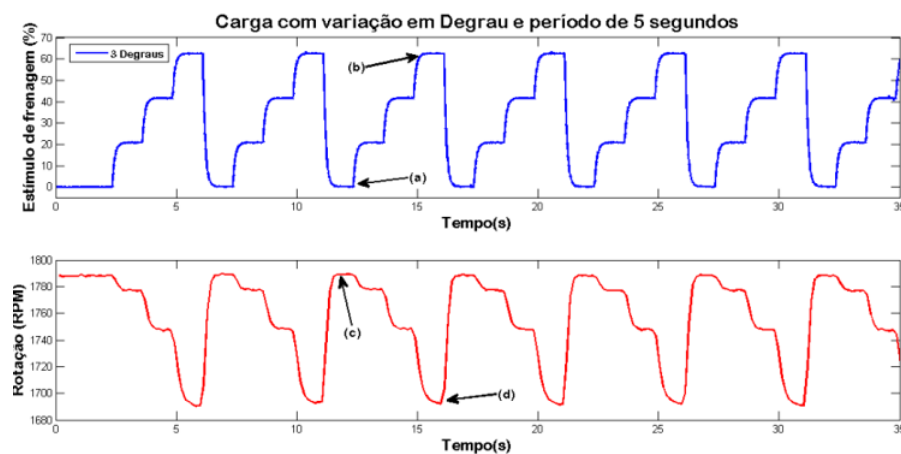
O *duty cycle* do sinal PWM gerado pela Unidade de Controle corresponde ao

<sup>6</sup>Encoders são dispositivos/sensores eletro-mecânicos, cuja funcionalidade é transformar posição em sinal elétrico digital.

estímulo de frenagem aplicado para frear o motor de indução, dessa forma a variação percentual do *duty cycle* controla a carga aplicada ao motor, podendo variar entre 0% e 100%. A fim de garantir os limites de segurança estipulados pelo fabricante do motor, Soares (2017) realizou testes no modo MANUAL, estes evidenciaram que para o motor instalado na bancada, o estímulo de carga aplicada não deve ultrapassar a 65% do sinal PWM. Nas simulações o *duty cycle* foi limitado em 60%, garantindo os limites de segurança de carga do motor.

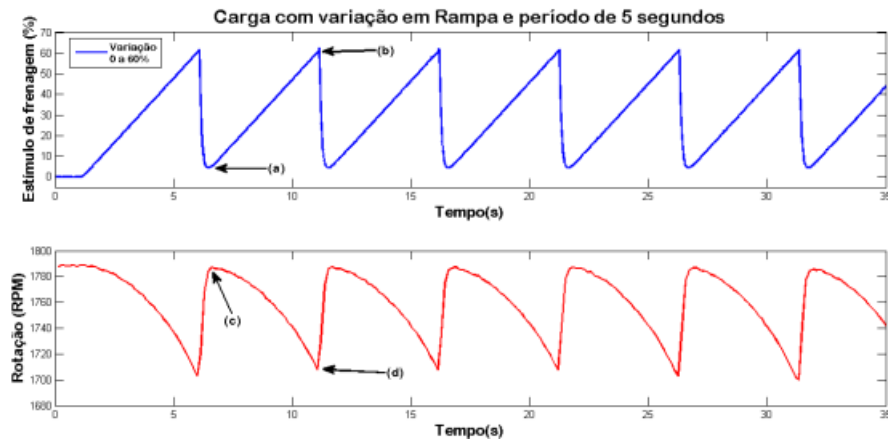
É ilustrado na Figura 28 a descrição de comportamento não linear a partir do sinais de estímulo do tipo degrau. Os sinais de frenagem são compostos por períodos de 5 segundos com três degraus que incrementam 20% no *duty cycle* cada. Em avaliação realizada por Soares (2017), são indicados na Figura 28, os trechos (a) e (b) no sinal de entrada possuem a mesma variação no estímulo, estes correspondem aos trechos (c) e (d) no sinal de velocidade. Ao comparar os sinais de estímulos com os de velocidade, observou-se uma não correspondência linear, isto é, para variações do *duty cycle* próximas de 0%, não foi obtida diminuição significativa na velocidade de rotação. No entanto, para as mesmas variações próximas aos 60%, as reduções de velocidades foram consideráveis.

**Figura 28** – Sinais de entrada em degraus e saída



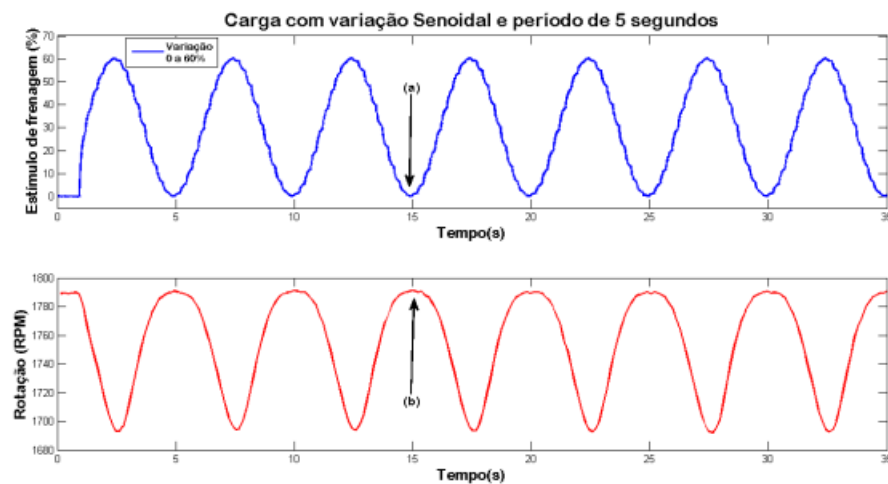
Fonte: (SOARES, 2017)

A não-linearidade também pode ser observada nos sinais de entrada em rampa a partir da Figura 33. Os sinais de velocidade do motor para esse perfil de entrada são similares a um sistema de primeira ordem.

**Figura 29** – Sinais de entrada em rampa e saída

Fonte: (SOARES, 2017)

O aspecto dinâmico é observado na resposta a uma entrada senoidal nos picos inferiores e superiores do sinal de RPM. Na base do sinal de saída, a forma de onda é mais estreita, já na crista da forma de onda, é mais concava. Essas características diferencia-o dos sinais considerados senoidais. É exibido na Figura 34 os sinais de estímulo de senoide em PWM e a resposta do motor de indução em RPM.

**Figura 30** – Sinais de entrada senoidal e saída

Fonte: (SOARES, 2017)

A fim de melhorar o controle dos sinais de saídas de velocidade do motor, o presente trabalho tem a proposta de aplicar Redes Neurais Artificiais (RNA) para caracterização do sistema e com isso definir os sinais de entrada para um comportamento desejado na saída.

---


## METODOLOGIA

### 5.1 SINAIS DE FRENAGEM

Com o intuito de agregar a Bancada, dando um aspecto de modernidade, foi realizado a substituição do motor monofásico por um trifásico de 1/2 Cavalo-Vapor (cv), visto que o motor original já era antigo e apresentava alguns desgastes. O estímulo de frenagem aplicado para frear o motor de indução, corresponde ao valor em percentual de *duty cycle* do sinal PWM gerado pela Unidade de Controle, desta forma a carga aplicada ao motor pôde variar entre 0% e 100%.

Para as simulações de carga, foram gerados sinais com perfis de carga dos tipos senoide e rampa com variações de períodos e *duty cycle*. Os perfis do tipo senoidais tiveram períodos de 5 e 10 segundos com variações de 0% a 100% e 40% a 60% do *duty cycle*, os quais podem ser observados na Figura 31.

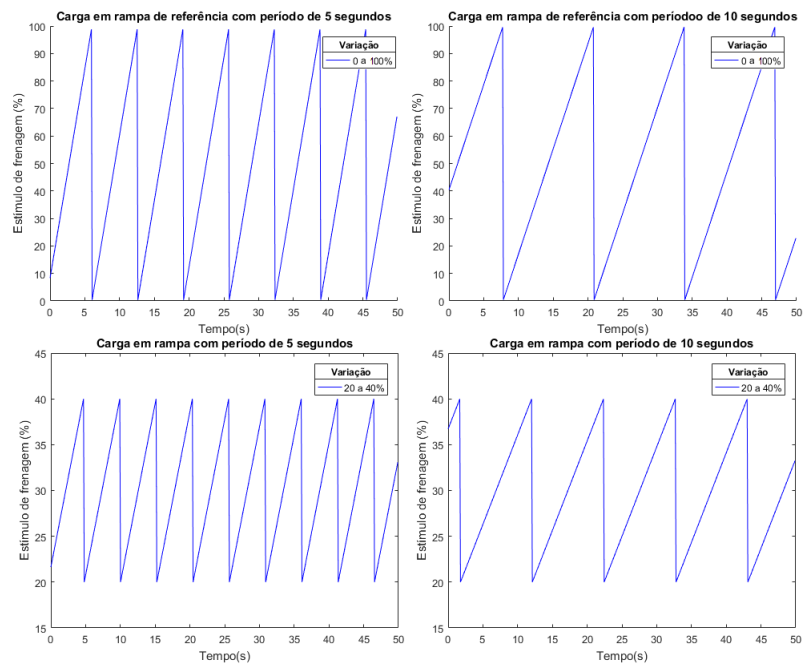
**Figura 31** – Sinais de entrada senoidal




Fonte: Próprio autor

Os perfis de rampa também tiveram períodos com 5 e 10 segundos de duração e as amplitudes de 0% a 100% e 20% a 40% do duty cycle podem ser observadas na Figura 32, as amplitudes de 40% a 60% e 50% a 70% *duty cycle* estão dispostos na Figura 33.

**Figura 32** – Sinais de entrada em rampa de 0% a 100% e 20% a 40% de *duty cycle*



Fonte: O Autor

**Figura 33** – Sinais de entrada em rampa de 40% a 60% e 50% a 70% *duty cycle*

Fonte: Próprio autor

## 5.2 AQUISIÇÃO DE DADOS

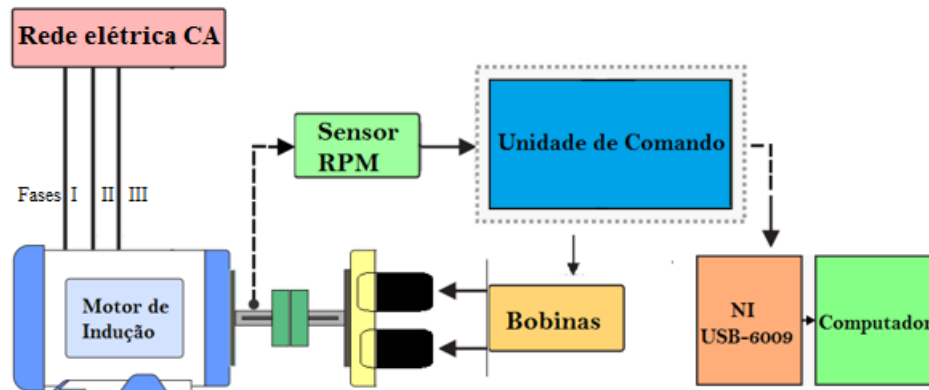
A aquisição de dados de velocidade do motor gerados a partir das simulações de carga na bancada, foram realizadas por um dispositivo de aquisição desenvolvida pela NI USB-6009. Esse equipamento permite capturar dados de dispositivos externos e enviar diretamente para o computador, o dispositivo pode ser observado na Figura 34. Já os sinais de entrada, foram usados os dados que produziram os sinais de estímulo.

**Figura 34** – Dispositivo de aquisição NI USB-6009

Fonte: Próprio autor

Para melhor compreensão, a aquisição das informações pode ser visualizada através de um diagrama exibido na Figura 35.

**Figura 35** – Diagrama básico para coleta de dados




Fonte: Próprio autor

O MATLAB<sup>®</sup> é um *software* interativo de alta performance capaz de executar processamentos de sinais, construção de gráficos, análise e simulação de modelos matemáticos aplicados às mais diversas áreas. Neste trabalho o MATLAB<sup>®</sup> foi usado por meio de códigos de linha de comando para tratamento e treinamento da RNA dos dados coletados pelas simulações.


O período de amostragem de cada sinal teve duração de 50 segundos e a frequência foi de 2000 Hz, totalizando 10000 amostras de por sinal. A captura de dados foi realizada enviando o sinal de onda quadrada do sensor de velocidade RPM ao canal 0 da placa de aquisição, os dados capturados foram enviados para o MATLAB<sup>®</sup>, e através de um algoritmo *Short Time Chirp-Z Transform* (STCZT) os resultados das simulações foram exibidos nos gráficos.

Após analisar os dados de saída, verificou-se o que já era esperado, as curvas de velocidade tiveram um comportamento semelhante a um sistema de primeira ordem, assim como nos resultados obtidos por Soares (2017). Na Figura 36 pode ser observado exemplos dessa características, nela estão dispostos sinais de estímulo do tipo senoidal com variação de 0% a 100% de *duty cycle* do PWM em azul, e os de velocidade em PWM em vermelho.

Esse comportamento também foi observado nos sinais de estímulo do tipo rampa, na Figura 37 estão dispostos gráficos contendo esses sinais com variação de 0% a 100% de *duty cycle* do PWM em azul, as velocidades em RPM correspondentes sinais em vermelho.

**Figura 36** – Sinais de entrada senoidal e sinal de saída em RPM

Fonte: Próprio autor

**Figura 37** – Sinais de entrada em rampa e sinal de saída em RPM

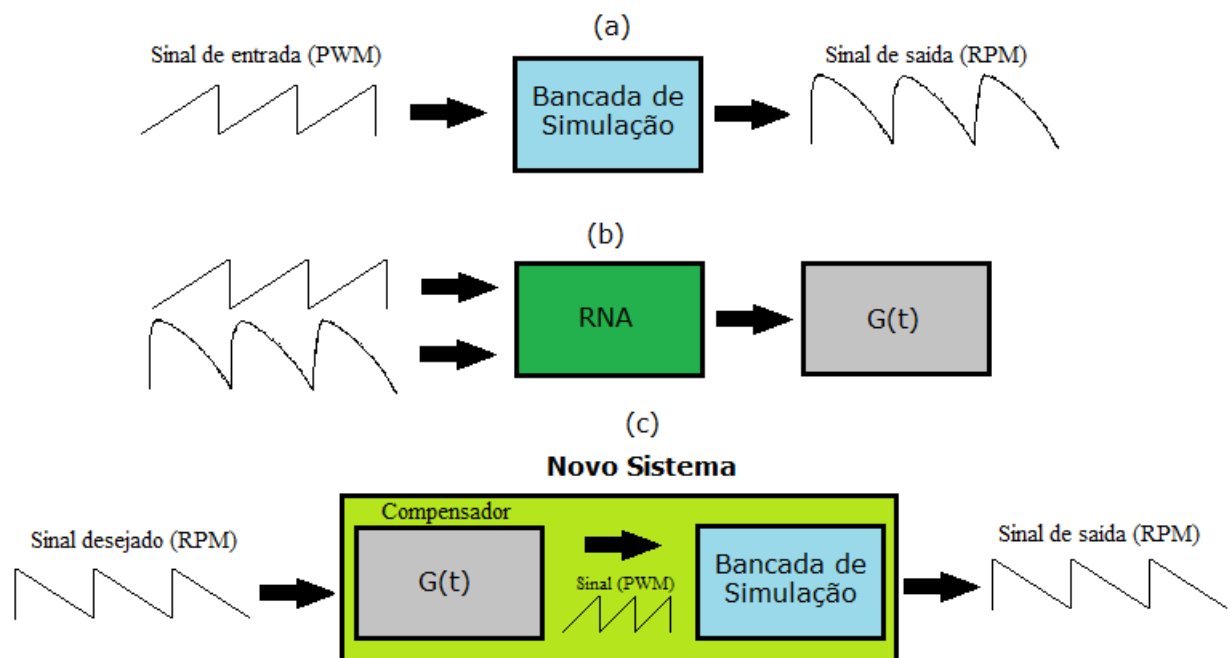
Fonte: Próprio autor

## 5.3 IMPLEMENTAÇÃO DA REDE NEURAL ARTIFICIAL

Tendo em vista a resposta da Bancada para sinais de entrada, isto é, a velocidade do motor a partir dos sinais de frenagens aplicados as bobinas, a RNA foi aplicada para aprender a correlação entre e os sinais de frenagens e os de velocidade RPM.

Para o treinamento, foi utilizado como dados de entrada da RNA, os sinais de velocidade obtidos a partir da captura do sensor óptico e processados através do algoritmo STCZT, os dados de saída, foram definidos como os sinais de PWM gerados pelas funções características. Com isso, a rede Neural pôde aprender a relação entre esses sinais variando os pesos da função associada a rede. Dessa forma, ao definir o perfil de velocidade desejado, este é utilizado na RNA para a obtenção do sinal de carga que será aplicado nas bobinas dos freios eletromagnéticos, fazendo com que a velocidade do motor siga o perfil determinado inicialmente. Na Figura 38 possui um diagrama do funcionamento da Bancada sem e com a implementação da RNA.

**Figura 38** – Diagrama de funcionamento da Bancada sem e com a aplicação de RNA



Fonte: Próprio autor

Na Figura 38 (a), é mostrado o comportamento da bancada de simulação antes da aplicação de RNA, o sinal de saída, de forma natural, não corresponde linearmente com o sinal de entrada. Como no exemplo, caso o sinal aplicado seja de primeira ordem, a resposta do sistema apresenta características de sinais de segunda ordem.

Na Figura 38 (b) é exibido o procedimento da aplicação da RNA representado pelo bloco  $G(t)$ . A maior parte dos dados de entrada e saída são usados para o treinamento, os dados separados são usados para a validação da RNA, e a partir do treinamento, ela aprende o funcionamento do sistema que responde o comportamento dinâmico.

Na Figura 38 (c) é retratado o novo sistema, após a implementação da rede, será fornecido a RNA um perfil de comportamento arbitrário, a Rede Neural fará as associações para um sinal de PWM que corresponde a esse dado perfil.

### 5.3.1 ARQUITETURA

As Redes Neurais podem ser estruturadas de várias maneiras para atender diversas aplicações, o modo como de organizar os neurônios em camadas e a conexões entre eles definem a arquitetura da rede. A rede adotada para este trabalho foi a *Feedforward* de múltiplas camadas, essa se caracteriza pela presença de uma ou mais camadas ocultas, por isso, é capaz de extrair estatísticas de ordem elevada.

Nessa arquitetura, as conexões da camada de entrada entregam os sinais iniciais, formado pelo padrão de ativação que é transmitido como entrada para os neurônios na camada seguinte, também conhecida como a primeira camada oculta. Esses sinais, após o processamento na segunda camada, então servem como entrada para a próxima camada de neurônios, dando continuidade ao fluxo de informação na rede.

A função de ativação tem o papel de limitar a saída do neurônio e usualmente é não-linear (FIORI, 2007). De acordo com a aplicação, é uma função matemática aplicada à combinação linear das variáveis de entrada ponderadas pelos pesos, ajudando a determinar a relação entre as entradas e as saídas do neurônio.

A rede desenvolvida para aplicação deste trabalho possui 2 camadas e as funções de ativação são a sigmoide (*Logsig*) e a tangente hiperbólica (*Tansig*) respectivamente. A função sigmoide tem grande importância pelo fato da sua capacidade de diferenciabilidade, ela admite que o valor de saída do neurônio assuma o intervalo contínuo entre 0 e 1. Já a função tangente hiperbólica pode-se adequar o valor de saída do neurônio conforme as características da função e assume valores no intervalo contínuo de -1 e 1.

### 5.3.2 TREINAMENTO

Para o treinamento da RNA, é necessário a definição dos vetores de entrada e saída a fim estabelecer uma relação entre eles. O vetor de entrada é composto pelos dados que representam a velocidade do motor em RPM, já o de saída, é composto pelos sinais de frenagem em PWM. A partir disso, foram separados 20% desses dados para validação da

rede, os 80% restantes para o treinamento.

A validação é realizada a partir análise do erro médio quadrático, do inglês, (*Mean Squared Error*). O MSE é calculado a partir dos dados separados para a validação, após o treinamento, os dados de entrada separados inicialmente são aplicados a rede, e a resposta é comparada com as saídas correspondentes através da Equação 8:

$$e = \frac{\sum_i^n \sqrt{(y_i - y_{rna_i})^2}}{n} \quad (8)$$

Onde:

$e$  - é o erro MSE;

$y_i$  - são os dados de saída separados inicialmente;

$y_{rna_i}$  - são os elementos obtidos a partir da resposta da RNA referente aos dados de entrada destacados previamente;

$i$  e  $n$  - correspondem ao primeiro e último elementos dos vetores respectivamente;

Os parâmetros de convergência em uma rede neural artificial são fundamentais para a rede atingir um estado satisfatório no treinamento. Na busca da melhor configuração dos parâmetros de convergência, variou-os nas seguintes faixas, 1 a 50 para a quantidade de neurônios em cada camada (duas camadas), 0,1 a 0,5 para a taxa de aprendizagem e 0,6 a 1 para o momento, totalizando 62500 variações de rede para cada sinal. As 10 configurações de parâmetros que apresentaram menores valores de erro para cada rede foram inseridas em uma tabela.

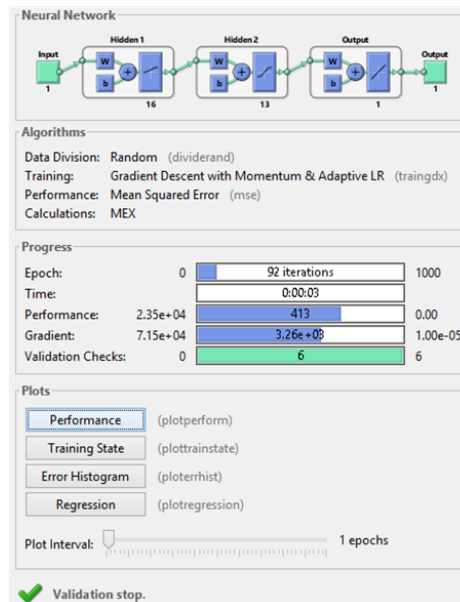
Foi realizado um refinamento com as redes destacadas, onde novamente por treinamento, variou a taxa de aprendizagem em cerca de 15000 simulações para diminuir o valor de erro e otimizar os resultados. Na Tabela 1 são apresentado o número de neurônios em cada camada das melhores RNA's encontradas para o sinal senoidal.

**Tabela 1** – Valores de erro para N° de neurônios em cada camada da RNA para o sinal senoidal

N° camada 1	N° camada 2	Erro MSE	Erro atualizado MSE
16	13	11,19	10,31
5	9	11,13	10,80
7	9	11,61	10,84
18	10	11,22	10,86
34	26	11,74	10,96
37	15	11,13	11,08
6	24	11,29	11,10
20	35	11,73	11,13
11	15	11,31	11,29
30	10	11,68	11,46

Por apresentar um baixo valor de erro na primeira simulação e o menor nas simulações de confirmação da RNA evidenciado na Tabela 1, a arquitetura da rede ficou com 16 neurônios na primeira camada e 13 na segunda camada. Observe na Figura 39 a arquitetura e treinamento da Rede Neural para o sinal senoide.


**Figura 39** – Arquitetura e treinamento da RNA para o sinal senoide



Fonte: Próprio autor

O gráfico da performance do treinamento pode ser observado na Figura 40 a seguir.

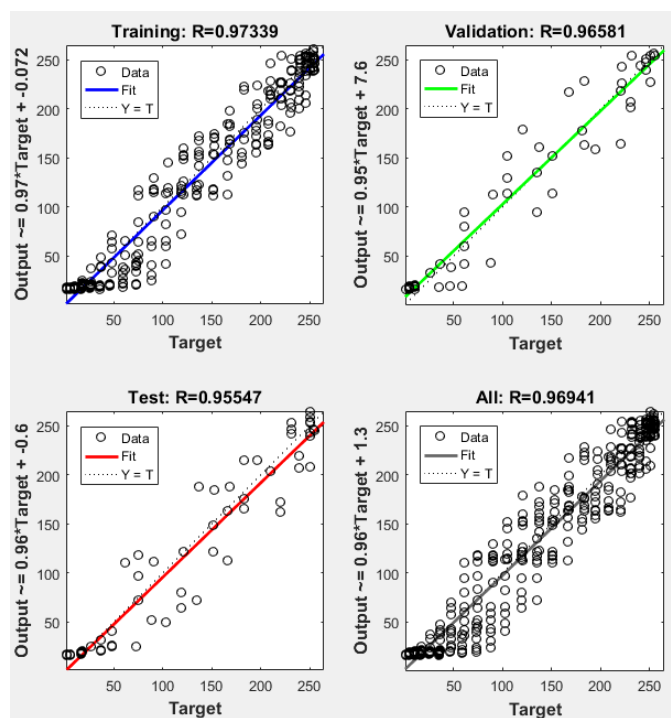
**Figura 40** – Gráfico da performance da RNA para o sinal senoide



Fonte: Próprio autor

Os gráficos de regressão do treinamento da RNA para o sinal senoide estão dipostos na Figura 41 a seguir.

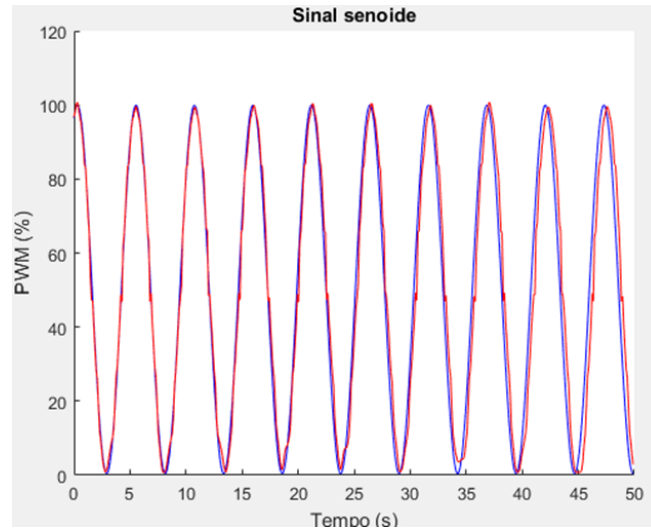
**Figura 41** – Gráficos de regressão no treinamento para o sinal senoide



Fonte: Próprio autor

Na Figura 42 é ilustrado o gráfico de comparação dos sinais de referência (em azul) e o do fornecido pela rede neural (em vermelho) após o treinamento e validação.

**Figura 42** – Sinais de referência e o fornecido pela RNA




Fonte: Próprio autor

Ao analisar o gráfico do sinal senoide, nota-se uma ótima aproximação do sinal gerado pela rede com o sinal de referência, sobrepondo-o na maioria dos pontos.

Foi plotado os gráficos de comparação para os dados que foram separados para validação (em azul) com os dados fornecidos pela rede (em vermelho), que pode ser observado na Figura 43.

**Figura 43** – Gráficos dos dados separados e dos fornecidos pela rede para o sinal senoidal



Fonte: Próprio autor

Da mesma forma, foi feito para o sinal em rampa. Os valores estão dispostos na Tabela 2 a seguir.

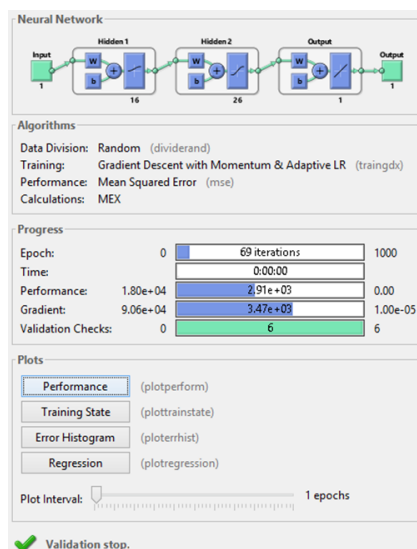
**Tabela 2** – Valores dos 10 menores erros para N° de neurônios em cada camada da RNA para o sinal em rampa

N° camada 1	N° camada 2	Erro MSE	Erro atualizado MSE
16	26	17,57	13,76
6	50	17,51	14,04
16	36	18,59	16,07
11	13	17,80	16,58
16	31	17,68	16,62
18	15	18,54	16,80
9	19	18,02	16,88
2	11	18,53	17,19
22	18	18,36	17,53
50	37	17,99	17,74

Ao observar a coluna de erros atualizados conclui-se que o refinamento se mostrou mais uma vez muito importante, uma vez que diminuiu consideravelmente os valores de erro médio de algumas redes e da rede escolhida.

Os valores de erros obtidos foram maiores para as redes do sinal em rampa, e entre elas, a arquitetura da rede escolhida apresenta um dos menores valores de erro nas simulações e o menor na confirmação da rede, dispondo de 16 neurônios na primeira camada e 26 neurônios na segunda. Observe a Figura 44, nela estão dispostos o treinamento e a arquitetura da rede.


**Figura 44** – Treinamento e arquitetura da rede para o sinal em rampa



Fonte: Próprio autor

A performance da Rede Neural para o sinal em rampa pode ser observada através do gráfico disposto na Figura 45 a seguir.

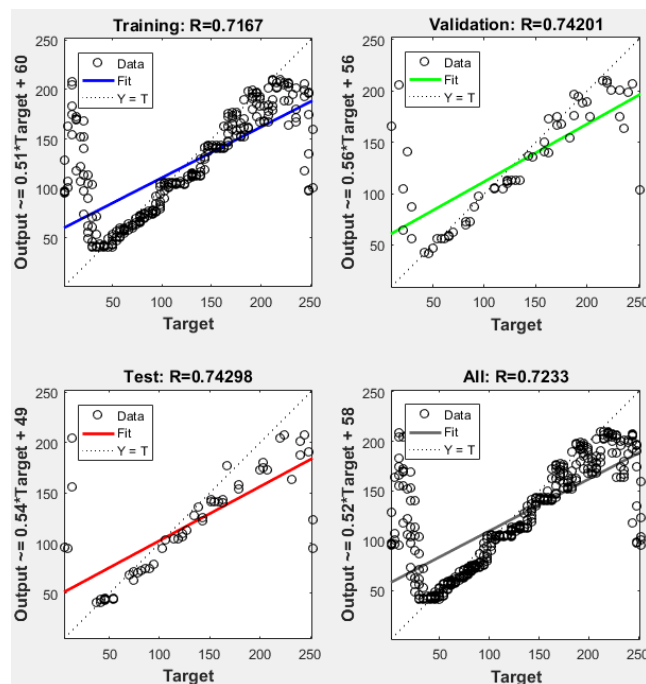
**Figura 45** – Gráfico da performance da RNA para o sinal em rampa



Fonte: Próprio autor

Os gráficos da regressão obtida no treinamento da RNA para o sinal em rampa podem ser observados na Figura 46.

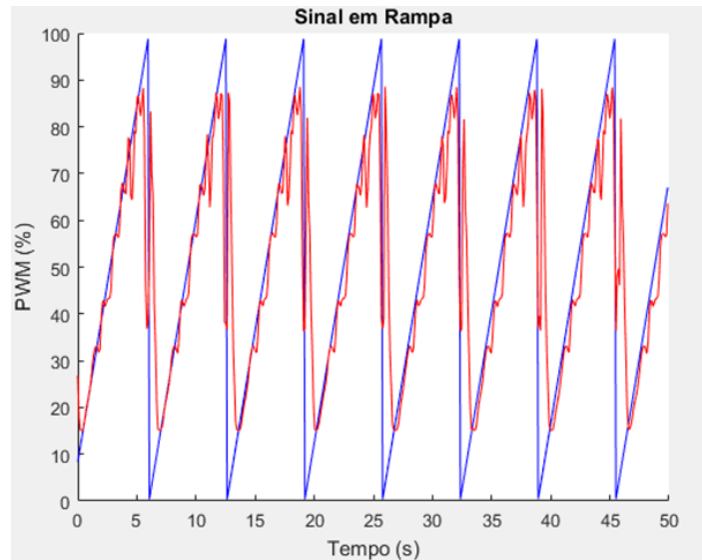
**Figura 46** – Gráfico da performance da RNA para o sinal em rampa



Fonte: Próprio autor

Na Figura 47 estão exibidos os gráficos de comparação dos sinais de referência (em azul) e o sinal fornecido pela RNA para o sinal em rampa (em vermelho).


**Figura 47** – Sinal de referência e sinal fornecido pela RNA



Fonte: Próprio autor

Os gráficos de comparação para os dados que foram separados para validação (em azul) com os dados fornecidos pela rede (em vermelho) para o sinal em rampa estão exibidos na Figura 48 a seguir.

**Figura 48** – Gráficos dos dados separados e dos fornecidos pela rede para o sinal em rampa



Fonte: Próprio autor

---

## CONCLUSÃO

Neste trabalho realizou-se a aplicação de Redes Neurais Artificiais (RNA) para o controle de carga baseado no sistema de Simulação desenvolvido por Soares (2017) que por sua vez, evidenciou um comportamento dinâmico não-linear.

De início, foram exibidos trabalhos com temáticas semelhantes para controle de carga, identificação de sistemas não-lineares e de aplicações de RNA. Além disso, foi destacada a importância da criação deste trabalho, que busca abordar lacunas existentes na área e contribuir significativamente para o avanço do conhecimento e das práticas relacionadas. De forma sucinta, foi apresentada a teoria necessária para a compreensão do trabalho, incluindo o neurônio artificial, as arquiteturas mais utilizadas na literatura e as funções de ativação mais frequentes. Também foram discutidos os sinais recorrentes na engenharia e a explicação da Modulação por Largura de Pulso (PWM).

Apresentou-se a Bancada de Simulação criada por Soares (2017) que incentivou a criação deste trabalho, incluindo a Unidade de Controle, Drive de Potência, Sistema de Frenagem e seus funcionamentos. Apresentou-se também as simulações feitas pelo autor e a característica dinâmica do sistema. Na metodologia foram descritos os sinais de frenagem utilizados, a aquisição e o tratamento dos dados. Foi descrito o processo de treinamento e o de melhoramento através da varredura da taxa de aprendizagem.

A aplicação e treinamento da RNA foi feita partir da coleta de dados, analisando os elementos de entrada e saída dos sinais dos tipos: senoidal e rampa. A arquitetura da RNA implementada é do tipo *Feedforward* de múltiplas camadas, onde possui 2 camadas de neurônios com as funções de ativação do tipo sigmoide (*Logsig*) e a tangente hiperbólica (*Tansig*) respectivamente.

As camadas da RNA para o sinal do tipo senoidal possuem 16 e 13 neurônios

respectivamente, e após o treinamento apresentou um erro médio quadrático (MSE) de 10,31. Para o sinal do tipo rampa, as camadas possuem 16 e 26 neurônios cada, e apresentou 13,76 de erro depois do treinamento. Os resultados apresentados neste trabalho mostraram que a arquitetura da RNA utilizada para os sinais aplicados se apresentou satisfatória, uma vez que a rede foi capaz de aprender o funcionamento do sistema e obter resultados que fossem capazes de realizar as compensações para obter os comportamentos aproximados aos dos desejados. Outras arquiteturas podem ser exploradas para esse tipo de sinal, uma vez que a rede neural possui muitas possibilidades para se adaptar às mais diversas necessidades.

Por fim, salienta-se que a metodologia utilizada nesse trabalho é adequada para modelos com comportamentos não-lineares e pode ser aplicada em sistemas que apresentem dinâmica complexa. A proposta deste estudo foi o desenvolvimento de uma Rede Neural Artificial, tendo como base o comportamento não-linear identificado na bancada de simulação criada por Soares (2017). Como sugestão para trabalhos futuros, recomenda-se explorar a aplicação prática dessa metodologia na bancada de Soares (2017), o que pode oferecer novas observações e validações práticas. A Rede Neural Artificial demonstrou eficácia na análise e aprendizado com os dados, evidenciando seu potencial para enriquecer a investigação e o aprimoramento de sistemas complexos e variáveis.

---

## Referências Bibliográficas

BORDON, M. E.; FRANCHIN, M. N.; CASTANHO, J. E. *Aplicação de um Sistema Neuro Nebuloso no Controle de um Motor de Indução*. Departamento de Engenharia Elétrica, Faculdade de Engenharia - UNESP, Bauru, SP, 2004.

CARDOSO, F. S. et al. O uso da inteligência artificial na educação e seus benefícios: uma revisão exploratória e bibliográfica. *Revista Ciência em Evidência*, v. 4, n. FC, p. e023002–e023002, 2023.

CASTELLS, M. “chatgpt”. la vanguardia. 2023. Disponível em: <<https://www.lavanguardia.com/opinion/20230225/8782438/chatgpt.html>>.

CHAPMAN, S. J. *Fundamentos de máquinas elétricas*. [S.l.]: AMGH editora, 2013.

DEMIDENKO, S. et al. *Induction motor control using load profiling measurement and processing*. In: IEEE. *IMTC 2001. Proceedings of the 18th IEEE Instrumentation and Measurement Technology Conference. Rediscovering Measurement in the Age of Informatics (Cat. No. 01CH 37188)*. Budapest, Hungria, 2001. v. 1, p. 599–604.

FERREIRA, R. C. V.; GARCIA, G. H. M.; BRASIL, D. R. O surgimento do chat gpt e a insegurança sobre o futuro dos trabalhos acadêmicos. *Cadernos de Direito Actual*, n. 21, p. 130–143, jun. 2023.

FERREIRA, S. “os filmes mais afetados pela greve de roteiristas e atores de hollywood”. 2023. Disponível em: <<https://epocanegocios.globo.com/mundo/noticia/2023/07/os-filmes-mais-afetados-pela-greve-de-roteiristas-e-atores-de-hollywood.ghtml>>.

FIORI, E. M. G. *Identificação De Sistemas Não-Lineares Utilizando Redes Neurais Artificiais*. Universidade Regional do Noroeste do Estado do Rio Grande do Sul - UNIJUÍ, Ijuí - RS, 2007.

FRANCHI, C. M. *Acionamentos elétricos*. Pinheiros - SP: Saraiva Educação SA, 2018.

FRIZZO, L. A. *Aplicação de redes neurais artificiais na identificação de sistemas não-lineares: estudo de caso em motor de indução*. Monografia (Trabalho de Conclusão de Curso) — Universidade Regional do Noroeste do Estado do Rio Grande do Sul - UNIJUÍ, Ijuí - RS, 2020.

FUSARO, A. C. et al. *Inteligência artificial e a ilusão do percepto afetivo*. Pontifícia Universidade Católica de São Paulo, 2018.

HAYKIN, S. *Neural networks: a comprehensive foundation prentice-hall upper saddle river. NJ MATH Google Scholar*, 1999.

- HAYKIN, S. *Redes neurais: princípios e prática*. [S.l.]: Bookman Editora, 2001.
- HAYKIN, S. S.; VEEN, B. V. *Sinais e sistemas*. Porto Alegre - RS: Bookman, 2001.
- HERNANDEZ, E. D. M. *Inteligência Computacional e Redes Neurais em Engenharia Elétrica. PSI-2222. Práticas de Eletricidade e Eletrônica II. EPUSP*, São Paulo - SP, 2005.
- KOTLINSKI, E. *Detecção de falta de alta impedância em sistema de distribuição radial utilizando redes neurais artificiais*. Universidade Regional do Noroeste do Estado do Rio Grande do Sul - UNIJUÍ, Ijuí - RS, 2013.
- MAZHARI, I.; VAHEDI, A.; MASOUM, M. *Induction motor load generator system using direct torque control method*. In: IEEE. *2007 Australasian Universities Power Engineering Conference*. Perth, WA, Australia, 2007. p. 1–6.
- MCCULLOCH, W. S.; PITTS, W. *A logical calculus of the ideas immanent in nervous activity. The bulletin of mathematical biophysics*, Springer, v. 5, n. 4, p. 115–133, 1943.
- MICROCHIP, P. Pic18f2455/2550/4455/4550 28/40/44-pin, high-performance. *Enhanced Flash, USB Microcontroller with nano Watt Technology (Datasheet)*, 2006.
- MIRANDA, S. T. d. *Aplicação de lógica fuzzy e redes neurais artificiais na previsão de carga à longo prazo considerando a elasticidade-preço da demanda*. 2017.
- NISE, N. S.; SILVA, F. R. da. *Engenharia de sistemas de controle*. California State University, CA, USA: LTC, 2002. v. 6.
- RASHID, M. H. et al. *Eletrônica de potência: circuitos, dispositivos e aplicações*. São Paulo - SP: Makron, 1999.
- ROSA, R. T. S. da et al. *Identificação de Sistemas Não Lineares de Estados Utilizando Redes Neurais Artificiais. Revista Mundi Engenharia, Tecnologia e Gestão (ISSN: 2525-4782)*, Curitiba, PR, v. 2, n. 2, 2017.
- SILVA, C. T. d. et al. *Saúde do trabalhador: um desafio para qualidade total no Hemorio*. Tese (Doutorado), 2000.
- SILVA, W. L. *"Utilização de métodos não invasivos para determinação de velocidade, escorregamento, e torque em motores de indução trifásico com aplicações em unidade de bombeio mecânico de petróleo"*. Tese (Doutorado), 2014.
- SOARES, A. d. C. *Construção de uma bancada didática para simulação de carga em motores de indução*. Monografia (Trabalho de Conclusão de Curso) — Faculdade Independente do Nordeste - FAINOR, Vitória da Conquista - BA, 2017.
- WAIDE, P.; BRUNNER, C. U. *Energy-efficiency policy opportunities for electric motor-driven systems*. 2011.
- WEG. *Motores elétricos de corrente alternada*. 2005.

CorujaT<sub>E</sub>X



Este volume foi tipografado em L<sup>A</sup>T<sub>E</sub>X na classe CorujaT<sub>E</sub>X como uma demanda do Colegiado do curso de Engenharia Elétrica da Universidade Federal do Oeste da Bahia (UFOB) ([https://github.com/ademariocarvalho/CCEE\\_UFOB\\_CorujaTEX](https://github.com/ademariocarvalho/CCEE_UFOB_CorujaTEX)).