

INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DE GOIÁS
CÂMPUS JATAÍ
BACHARELADO EM ENGENHARIA ELÉTRICA

GUILHERME FERREIRA LIMA

RNA PARA MONITORAMENTO E PROTEÇÃO DE MÁQUINAS ELÉTRICAS

Jataí - GO

2022



INSTITUTO FEDERAL
Goiás

MINISTÉRIO DA EDUCAÇÃO
SECRETARIA DE EDUCAÇÃO PROFISSIONAL E TECNOLÓGICA
INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA
PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO
SISTEMA INTEGRADO DE BIBLIOTECAS

TERMO DE AUTORIZAÇÃO PARA DISPONIBILIZAÇÃO NO REPOSITÓRIO DIGITAL DO IFG - ReDi IFG

Com base no disposto na Lei Federal nº 9.610/98, AUTORIZO o Instituto Federal de Educação, Ciência e Tecnologia de Goiás, a disponibilizar gratuitamente o documento no Repositório Digital (ReDi IFG), sem ressarcimento de direitos autorais, conforme permissão assinada abaixo, em formato digital para fins de leitura, download e impressão, a título de divulgação da produção técnico-científica no IFG.

Identificação da Produção Técnico-Científica

- | | |
|--|---|
| ☐ Tese | ☐ Artigo Científico |
| ☐ Dissertação | ☐ Capítulo de Livro |
| ☐ Monografia - Especialização | ☐ Livro |
| ☒ TCC - Graduação | ☐ Trabalho Apresentado em Evento |
| ☐ Produto Técnico e Educacional - Tipo: _____ | |

Nome Completo do Autor: Guilherme Ferreira Lima

Matrícula: 20171020040070

Título do Trabalho: RNA Para Monitoramento e Proteção de Máquinas Elétricas

Autorização - Marque uma das opções

1. (☒) Autorizo disponibilizar meu trabalho no Repositório Digital do IFG (acesso aberto);
2. (☐) Autorizo disponibilizar meu trabalho no Repositório Digital do IFG somente após a data ____/____/____ (Embargo);
3. (☐) Não autorizo disponibilizar meu trabalho no Repositório Digital do IFG (acesso restrito).

Ao indicar a opção **2** ou **3**, marque a justificativa:

- (☐) O documento está sujeito a registro de patente.
(☐) O documento pode vir a ser publicado como livro, capítulo de livro ou artigo.
(☐) Outra justificativa: _____

DECLARAÇÃO DE DISTRIBUIÇÃO NÃO-EXCLUSIVA

O/A referido/a autor/a declara que:

- i. o documento é seu trabalho original, detém os direitos autorais da produção técnico-científica e não infringe os direitos de qualquer outra pessoa ou entidade;
- ii. obteve autorização de quaisquer materiais incluídos no documento do qual não detém os direitos de autor/a, para conceder ao Instituto Federal de Educação, Ciência e Tecnologia de Goiás os direitos requeridos e que este material cujos direitos autorais são de terceiros, estão claramente identificados e reconhecidos no texto ou conteúdo do documento entregue;
- iii. cumpriu quaisquer obrigações exigidas por contrato ou acordo, caso o documento entregue seja baseado em trabalho financiado ou apoiado por outra instituição que não o Instituto Federal de Educação, Ciência e Tecnologia de Goiás.

fatar _____, 20/04/2022
Local Data

Guilherme F. Lima

Assinatura do Autor e/ou Detentor dos Direitos Autorais

GUILHERME FERREIRA LIMA

RNA PARA MONITORAMENTO E PROTEÇÃO DE MÁQUINAS ELÉTRICAS

Trabalho de Conclusão de curso apresentado ao
Instituto Federal de Educação, Ciência e
Tecnologia de Goiás, Campus Jataí para obtenção
do grau de Bacharel em Engenharia Elétrica.
Orientador: Prof. Dr. André Luiz Silva Pereira.

Jataí - GO

2022

Dados Internacionais de Catalogação na Publicação na (CIP)

Lima, Guilherme Ferreira.

RNA para monitoramento e proteção de máquinas elétricas [manuscrito] / Guilherme Ferreira Lima. -- Jataí: IFG, Coordenação do Curso de Bacharelado em Engenharia Elétrica 2022.

27. ; il.

Orientador: Prof. Dr. André Luiz Silva Pereira.

Bibliografias.

1. Rede Neurais Artificiais. 2. Máquina Elétrica. 3. Código. 4. Aprendizagem. 5. Adaptação. I. Pereira, André Luiz Silva. II. IFG, Câmpus Jataí. III. Título.

Ficha catalográfica elaborada pela Seção Téc.: Aquisição e Tratamento da Informação.
Bibliotecária - Rosy Cristina O. Barbosa - CRB 1/2380 – C. Jataí. Cód. F036/2022-1.



INSTITUTO FEDERAL
Goiás

MINISTÉRIO DA EDUCAÇÃO
SECRETARIA DE EDUCAÇÃO PROFISSIONAL E TECNOLÓGICA
INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DE GOIÁS
CÂMPUS JATAÍ

Folha de Aprovação

GUILHERME FERREIRA LIMA

RNA PARA MONITORAMENTO E PROTEÇÃO DE MÁQUINAS ELÉTRICAS

Trabalho de Conclusão de Curso apresentado a Coordenação do Curso de Bacharelado em Engenharia Elétrica do Instituto Federal de Educação, Ciência e Tecnologia de Goiás – Câmpus Jataí, como parte dos requisitos para a obtenção do título de Bacharel em Engenharia Elétrica.

Monografia defendida e aprovada, em 4 de abril de 2022, pela banca examinadora constituída pelos seguintes membros:

BANCA EXAMINADORA

Prof. Dr. André Luiz Silva Pereira
Presidente da banca / Orientador
Instituto Federal de Educação, Ciência e Tecnologia de Goiás - Câmpus Jataí

Prof. Dr. Fernando Silva Pereira
Membro
Instituto Federal de Educação, Ciência e Tecnologia de Goiás - Câmpus Jataí

Prof. Ms. Dori Rodrigues de Souza
Membro
Instituto Federal de Educação, Ciência e Tecnologia de Goiás - Câmpus Jataí

Documento assinado eletronicamente por:

- **Fernando Silva Pereira**, PROFESSOR ENS BASICO TECN TECNOLOGICO, em 13/04/2022 16:06:00.
- **Dori Rodrigues de Souza**, PROFESSOR ENS BASICO TECN TECNOLOGICO, em 11/04/2022 21:01:37.
- **Andre Luiz Silva Pereira**, COORDENADOR - FUC1 - JAT-2CCTBE, em 11/04/2022 09:34:32.

Este documento foi emitido pelo SUAP em 04/04/2022. Para comprovar sua autenticidade, faça a leitura do QRCode ao lado ou acesse <https://suap.ifg.edu.br/autenticar-documento/> e forneça os dados abaixo:

Código Verificador: 266261

Código de Autenticação: ae8cfa6698



Instituto Federal de Educação, Ciência e Tecnologia de Goiás

Av. Presidente Juscelino Kubitschek, nº 775, Residencial Flamboyant, JATAÍ / GO, CEP 75804-714
(64) 3605-0843 (ramal: 843)

RESUMO

Com o grande o avanço do homem em sua busca de adaptações e desenvolvimentos fica evidente que o monitoramento e proteção de uma máquina elétrica trifásica se torna indispensável no momento atual. Dessa maneira, ao utilizar as Redes Neurais Artificiais (RNA), o operador recebe informações em tempo “real” da máquina, de modo que esta, por se encontrar naquele momento atual, estabeleça padrões, para que então, a partir deles, tome decisões de acordo com as necessidades apresentadas. Evidencia-se, portanto, que assim como os neurônios de um ser vivo que recebem, armazenam e aprendem com as informações desconhecidas recebidas, a utilização de RNA's melhora o desempenho da máquina elétrica, bem como, o seu tempo de vida útil, sendo, dessa forma, positivamente favorecido e se mostrando rentável. Para o desenvolvimento desse projeto, serão utilizadas duas Redes Neurais Artificiais no modelo *Adaline* distintas, sendo elas para o monitoramento e controle da temperatura e corrente, cada uma assumindo uma grandeza individualmente.

Palavras-chaves: Rede Neurais Artificiais. Máquina Elétrica. Código. Aprendizagem. Adaptação.

ABSTRACT

With the great advance of man in his search for adaptations and developments, it is clear the monitoring and protection of a three-phase electric machine becomes indispensable at the present time. Using Artificial Neural Networks (ANN) it is possible for the operator to receive information in "real" time from the machine in relation to what it is at that current moment and establish standards and from them make decisions according to the needs presented. As the neurons of a living being that receive, store and learn from the unknown information received, the use of ANNs proves to be profitable for the electrical machine, improving both its performance and its lifespan, which are positively favored. For this, two different Artificial Neural Networks will be used in the Adaline model, being them for the monitoring and control of the temperature and current, each one assuming an individual magnitude.

Keywords: Artificial Neural Networks. Electric Machine. Code. Learning. Adaptation.

LISTA DE FIGURAS

Figura 2.1. - Motor de indução trifásico.....	11
Figura 2.2. - Relação Vida útil x Temperatura.....	12
Figura 3.1. - Representação biológica de uma rede neural.....	14
Figura 3.2. - Representação Rede Neural Artificial.....	15
Figura 3.5. - Representação Rede <i>Adaline</i> de n entradas.....	16
Figura 4.1. - Representação da interface da plataforma <i>Matlab</i>	29

LISTA DE TABELAS

Tabela 4.1. - Representação da simulação realizada.....	21
Tabela 4.2. - Terceira tentativa com 100% de acertos.....	22

LISTA DE SIGLAS

X_n	– Variáveis de entrada
W_n	– Pesos sinápticos
θ	– Limiar de ativação
u	– Potencial de Ativação
g	– Função de Ativação
y	– Sinal de Saída
Σ	– Combinador Linear
d	– Saída desejada
v	– Resposta do combinador linear
η	– Constante que define a taxa de aprendizagem da rede

SUMÁRIO

1	INTRODUÇÃO	10
2	MÁQUINAS ELÉTRICAS TRIFÁSICAS	10
	2.1. <i>Preservação dos Motores de Indução Trifásico</i>	11
3	CARACTERÍSTICAS DAS RNA'S	12
	3.1. <i>Neurônio Biológico</i>	13
	3.2. <i>Neurônio Artificial</i>	14
	3.3. <i>Rede Adaline</i>	16
	3.4. <i>Treinamento da Rede Adaline</i>	17
4	Matlab.....	18
	4.1. <i>Desenvolvimento da Rede Neural Artificial</i>	19
5	CONCLUSÃO	23
6	REFERÊNCIAS BIBLIOGRÁFICAS	24
7	ANEXO	25

1 INTRODUÇÃO

As máquinas elétricas estão cada vez mais presentes em nosso cotidiano. Sua vasta utilização no nosso dia-a-dia, tanto no meio pessoal quanto em nosso ambiente de trabalho, gera facilidades, tais quais o aumento de precisão em determinadas situações, o não impacto ambiental como a emissão de gases poluentes e o poder de ser alimentado com fontes de energia renováveis e limpas (CHAPMAN, 2013).

Nesse sentido, podem ser destacados inúmeros benefícios acerca das máquinas elétricas, mas deve-se ter em mente que o dimensionamento correto do equipamento deve ser feito para preservar seu funcionamento, assim, evitando adventos como, por exemplo, o efeito *joule*. Esse fenômeno é causado quando os motores trabalham sobrecarregados, causando aquecimento no sistema, comprometendo seus enrolamentos, bobinas, escovas e principalmente sua vida útil (MAMEDE FILHO, 2017).


Para este trabalho, foi escolhido utilizar duas Redes Neurais Artificiais no modelo *Adaline* por possuir diversos benefícios como o algoritmo de aprendizado na regra Delta, função dada a partir da minimização quadrática dos erros, alta taxa de adaptação e reconhecimento de sinais analógicos, tendo essas características base a RNA *Adaline* passa a ser utilizada em diversas aplicações realizando classificação, identificação, monitoramento e controle de dados. Tendo estes benefícios, cada RNA ficará a cargo de uma grandeza (Temperatura e Corrente elétricas) melhorando assim o reconhecimento individual e evitando que ocorra erros para quando o sistema volte para suas condições nominais (SILVA *et al.*, 2016).

Em vista disso, o objetivo geral do trabalho é **(a)** programar e treinar a RNA para monitoramento e proteção de máquinas elétricas, e os objetivos específicos são **(b)** conhecer a RNA *Adaline* bem como sua aplicação prática; **(c)** aprender a implementar (programar e treinar) a *Adaline*; **(d)** desenvolver um algoritmo utilizando o *Matlab* para implementação da *Adaline*.

2 MÁQUINAS ELÉTRICAS TRIFÁSICAS

Os motores trifásicos são máquinas que convertem energia elétrica em energia mecânica quando alimentados por um sistema trifásico a três fios, onde suas tensões estão defasadas a 120° elétricos. Atualmente, corresponde por quase toda a concentração de motores elétricos empregados nas instalações elétricas (MAMEDE, 2017).

A seguir na Figura 2.1 é mostrado as partes constituintes de um motor de indução trifásico:

Figura 2.1. Motor de indução trifásico

Fonte: (MAMEDE, 2017, p. 333)

Os motores mais aplicados em indústrias são as máquinas assíncronas de indução alimentados com corrente alternada, por terem custo mais baixo, requerer menos manutenções e possuir vida útil com período de tempo maiores (MAMEDE, 2017). Desse modo, para seu funcionamento é aplicado corrente alternada nas bobinas do estator, excitando assim um campo magnético do motor de indução, este campo irá induzir corrente nos enrolamentos do rotor fazendo com que a máquina funcione (FITZGERALD *et al.*, 2014).

2.1. Preservação dos Motores de Indução Trifásico

Com o intuito de preservar o motor, deve-se respeitar os seus valores nominais de operação, caso não sejam respeitadas e seus valores estejam superiores aos recomendados, resultará em diversos problemas como curto-circuito, sobreaquecimento interno nos enrolamentos, danos severos na isolação e a queima do motor.

Segundo Mamede (2017), um aumento de 10°C sobre a isolação de um motor pode reduzir sua vida útil a metade da estabelecida originalmente. Assim, a elevação da temperatura pode desencadear sérios problemas à máquina e diminuir drasticamente seu tempo de vida útil.

Outro ponto importante a ser observado é sobre a corrente nominal de operação, esta oferecida pela rede elétrica deve ser entregue nos padrões para que as tensões e frequência sobre o motor também sigam em valores nominais (MAMEDE, 2017). Isto posto, quando um motor opera em grande regime de tempo com valores muito elevados de corrente elétrica, irá desencadear a elevação de temperatura sobre o mesmo, levando a sofrer os danos mencionados anteriormente (CHAPMAN, 2013).


Segundo (MAMEDE, 2017, p.344) “A norma agrupa os materiais isolantes e os sistemas de isolamento, no que se denomina classe de isolamento, e estes são limitados pela temperatura que cada material isolante pode suportar em regime contínuo sem que seja afetada sua vida útil.

São as seguintes as classes de isolamento empregadas em máquinas elétricas:

- Classe A – Limite 105°C: seda, algodão, papel e similares impregnados em líquidos isolantes: por exemplo: esmalte de fios;
- Classe E – Limite 120°C: fibras orgânicas sintéticas;
- Classe B – Limite 130°C: asbesto, mica e materiais a base de poliéster;
- Classe F – Limite 155°C: fibra de vidro, amianto associado a materiais sintéticos (silicones);
- Classe H – Limite 180°C: fibra de vidro, mica, asbesto, associado a silicones de alta estabilidade térmica.”

As classes mais utilizadas no mercado são: A, E e B, a preservação da temperatura do enrolamento se torna indispensável para preservar a vida útil do motor, conforme a Figura 2.2 onde é mostrada a relação entre a vida útil das isolações e a temperatura sobre os enrolamentos:

Figura 2.2. Relação Vida útil x Temperatura



Fonte: (MAMEDE, 2017, p.345)

Em vista do exposto, podemos perceber que a vida útil das isolações do motor, reduz em grande escala com o aumento gradual de temperatura, mostrando assim a importância de seu monitoramento e prevenção de possíveis sobrecargas.

3 CARACTERÍSTICAS DAS RNA's

O modo de processamento que as Redes Neurais Artificiais (RNA's) simulam são de forma singulares não tendo o mesmo paralelismo que ocorre no sistema cerebral biológico, porém possuem grande parentesco quando se trata de percepção, aprendizagem e adaptação

para as mais diversas áreas de aplicação por se tratar de algoritmos genéricos e de fácil manipulação quando se tem um sistema claro a ser seguido (HAYKIN, 2001).

A Rede Neural Artificial possui as seguintes características (SILVA et al, 2016).

- A RNA é capaz de observar o meio em que se encontra e através de sua observação se torna capaz de entender a melhor reação a ser tomada, isso se dá por ter que passar pelo treinamento onde a mesma irá aprender e diferenciar diversas situações que ocorrem no sistema que está implantada.
- A rede possui capacidade de prever soluções através da generalização do conhecimento, onde os problemas possuem situações que os dados de entrada resultam em soluções desconhecidas ou improváveis.
- Em seu treinamento, a rede separa os valores com características parecidas em grupos para que assim se possa facilitar sua interpretação e melhorar sua resposta para os diferentes tipos de entrada.
- O sistema possui alta tolerância a falhas, isso se dá devido a sua grande quantidade de interconexões neurais, uma conexão irá suprir o erro que a outra deixou passar, sendo necessário um evento extraordinário para que a rede deixe de agir da forma proposta, comprometendo assim sua estrutura.
- Possui interações lineares e sequenciais onde o conhecimento pode ser distribuído por todas as camadas da rede neural.
- Por sua programação ser de baixa complexidade, o sistema pode ser implementado em diversas áreas e plataforma que requerem respostas através de funções matemáticas possíveis.


Com as características apresentadas acima, as RNA's podem possuir diversas aplicações, sendo algumas delas: reconhecimento de voz através de software, reconhecimento de imagens possuindo padrões, avaliação de anomalias em operações médicas, monitoramento e controle de máquinas e aparelhos eletroeletrônicos (SILVA *et al.*, 2016).

3.1. Neurônio Biológico

Estima-se que em média o cérebro humano possui cerca de 86 bilhões de neurônios, e a junção destes se tornaria a Unidade Central de Processamento (CPU) do corpo, estes são responsáveis por gerenciar e processar todos os estímulos recebidos do ambiente através dos impulsos elétricos que se espalham por todo o corpo e atuar de acordo com eles demonstrando a resposta voluntária ou involuntária que se exerce ao executar algum movimento.

A seguir na Figura 3.1 é mostrado o esquema de uma rede neural biológica, representando suas partes constituintes.

Figura 3.1. Representação biológica de uma rede neural



Fonte: <https://www.sobiologia.com.br/conteudos/FisiologiaAnimal/nervoso2.php>

Observa-se que a composição principal destas células se forma em três principais partes: dendritos, corpo celular e axônio (SILVA *et al.*, 2016). Nesse sentido, os dendritos são os finos prolongamentos ramificados que conduzem estímulos elétricos captados do meio em que o corpo está localizado ou de outra célula, o maior volume do neurônio se encontra no corpo celular onde se localiza o núcleo e quase toda a estrutura citoplasmática, já os axônios são os finos prolongamentos que possuem como função transmitir as informações através dos impulsos nervosos para outro neurônios através das terminações do axônio utilizando as sinapse ou para as demais células do corpo humano (KANDEL *et al.*, 2014).


3.2. Neurônio Artificial

A necessidade de desenvolver formas artificiais de pensamento, faz com que seja necessário criar neurônios artificiais tendo grandes semelhanças com o biológico, estes também possuem paralelismo e alta conectividade como principais características individuais sendo capazes de receber, armazenar e repassar informações adiante na rede em que está localizado (SILVA *et al.*, 2016).

O neurônio artificial possui um ou mais sinais de entrada e somente um único sinal de saída onde as variáveis de entrada que são geradas a partir de sensores ou passadas de outro neurônio artificial que constitui a Rede Neural Artificial, são verificadas e enviadas para a saída.

Na Figura 3.2 é demonstrado o esquema de uma rede neural artificial:

Figura 3.2. Representação Rede Neural Artificial



Fonte: (SILVA *et al.*, 2016, p.34)

Segundo (SILVA *et al.*, 2016) as maiores características de um neurônio artificial são determinadas pelos seguintes elementos.

- Sinais de entradas representados pelos símbolos $\{X_1, X_2, \dots, X_n\}$, estes são fornecidos a partir de sensores ou de neurônios artificiais anteriores presentes na rede, tendo grande importância na incrementação e eficiência computacional do algoritmo.
- Pesos sinápticos representados pelos símbolos $\{W_1, W_2, \dots, W_n\}$, são valores que avaliam cada um dos sinais de entrada do neurônio, sendo assim é possível verificar sua relevância na aplicação do mesmo.
- Limiar de ativação representado pelo símbolo $\{\theta\}$, variável que determinará o nível em que o resultado do combinador linear gere um valor de disparo em direção a saída do neurônio.
- Combinador linear representado pelo símbolo $\{\Sigma\}$, agrega os sinais avaliados pelos pesos sinápticos com o objetivo de produzir um valor de potencial de ativação.
- Potencial de ativação representado pelo símbolo $\{u\}$, resultante gerada pela diferença entre o combinador linear e o limiar de ativação. Caso o valor gerado seja positivo, $u \geq \theta$, logo o neurônio irá produzir um potencial excitatório, caso contrário $u < \theta$, o potencial será inibitório.
- Função de ativação representado pelo símbolo $\{g\}$, possui função de limitar a saída do neurônio artificial dentro de uma faixa de valores a serem determinadas pela própria imagem funcional.

- Sinal de saída representado pelo símbolo $\{y\}$, valor final resultante pelo neurônio como resposta ao conjunto de variáveis de entrada, este também poderá servir como sinal de entrada para outros neurônios que seguem conectados na rede neural.

As referências a serem observadas são o polarizador e os pesos sinápticos, em cada neurônio gera a soma dos valores avaliados de todas as entradas, logo o polarizador será associado a uma entrada fixa de 1 e -1.

3.3. Rede *Adaline*

Segundo Silva *et al.*, 2016:


O Adaline foi idealizado por Widrow e Hoff em 1960, e sua principal aplicação se destinava a sistemas de chaveamento de circuitos telefônicos, sendo está uma das primeiras aplicações industriais que envolveram efetivamente a utilização das redes neurais artificiais (SILVA *et al.*, 2016, p.73).

Assim, no modelo *Adaline*, a estrutura é bem simples, pois possui apenas uma camada e um neurônio em sua estrutura, no entanto, segundo Silva *et al.* (2016), promoveu diferentes avanços muito importantes na área de redes neurais artificiais, são elas:

- Desenvolvimento do algoritmo de aprendizado na regra Delta.
- Aplicações em diversos problemas práticos envolvendo processamento de sinais analógicos.
- Primeiras aplicações industriais de redes neurais artificiais.

A seguir é demonstrado o esquema de um neurônio artificial no modelo *Adaline* representando suas diferenças e semelhanças com o modelo anterior:

Figura 3.3. Representação Rede *Adaline* de n entradas.



Fonte: (SILVA *et al.*, 2016, p. 74).

As saídas podem ser representadas pela seguinte expressão:

$$\begin{cases} u = \sum_{i=1}^n W_i \cdot X_i - \theta \Leftrightarrow u = \sum_{i=0}^n W_i \cdot X_i \\ y = g(u) \end{cases}$$

Com a presença do Bloco Associador na estrutura da rede, pode-se ter o sinal de erro sendo:

$$erro = d - u$$

Este bloco possui a função de auxiliar no processo de treinamento da rede, aumentando ou diminuindo o grau de proximidade da exatidão do sistema.

3.4. Treinamento da Rede Adaline

A rede neural no método *Adaline* utiliza a regra Delta foi desenvolvida por Widrow e Hoff em 1960, esta regra se caracteriza em ajustar os pesos e limiar do neurônio, minimizando a diferença entre a saída e a resposta do combinador linear, ou seja, é utilizado a minimização do erro quadrático entre u e d para que o vetor de pesos da rede seja ajustado. Obtendo um w^* tal qual o erro quadrático $\{E(w^*)\}$ em comparação com todo o conjunto de amostras seja o mínimo possível.

Dessa maneira, de acordo com Silva *et al.* (2016), temos que estas equações podem ser expressadas por:

$$E(w^*) \leq E(w), \forall w \in R^{n+1}$$

As p amostras de treinamento são dadas por:

$$\begin{aligned} E(w) &= \frac{1}{2} \sum_{k=1}^p (d^k - u) \\ E(w) &= \frac{1}{2} \sum_{k=1}^p (d^k - \sum_{i=1}^n W_i \cdot X_i^k - \theta)^2 \\ E(w) &= \frac{1}{2} \sum_{k=1}^p (d^k - (W^t \cdot X^k - \theta))^2 \end{aligned}$$

Utilizando o operador gradiente em analogia ao vetor de pesos, com objetivo de encontrar um valor ótimo para o erro quadrático.

$$\nabla E(w) = \frac{\partial E(W)}{\partial W}$$

A partir deste podemos obter:

$$\nabla E(w) = \sum_{k=1}^p (d^k - (W^t \cdot X^k - \theta)) \cdot (-X^k)$$

$$\nabla E(w) = - \sum_{k=1}^p (d^k - u) \cdot (X^k)$$

Os passos de adaptação do vetor de pesos devem ser efetuados em direção oposta à do gradiente para que seja minimizado o erro quadrado médio.

$$\Delta w = -\eta \cdot \nabla E(w)$$

$$\Delta w = -\eta \cdot \sum_{k=1}^p (d^k - u) \cdot (X^k)$$

Para simplificar o entendimento, a equação pode ser simplificada da seguinte forma:

$$W^{atual} = W^{anterior} + \eta \cdot \sum_{k=1}^p (d^k - u) \cdot (X^k)$$

$$W^{atual} = W^{anterior} + \eta \cdot (d^k - u) \cdot (X^k), \text{ onde } k = 1, \dots, p$$

4 Matlab

O *Matlab* é uma plataforma computacional criada para uso específico e otimizada, principalmente, para executar cálculos científicos e de engenharia. Criada possuindo linguagem de programação própria, oferecendo diversos recursos e funções predefinidas em sua biblioteca, tornando assim muito mais fácil e simples de resolver problemas nesta plataforma quando comparados em outras linguagens como: C, Fortran ou Python (CHAPMAN, 2003).

O programa possui diversas vantagens de utilização, são elas (CHAPMAN, 2003):


- Facilidade de uso, pode se utilizar como bloco de anotações para rascunhos e para criar, modificar e executar grandes programações feitas com grande facilidade, a plataforma oferece todo suporte necessário para auxiliar o usuário.
- Independência da plataforma, por possuir grande compatibilidade com vários sistemas computacionais, a plataforma se torna uma escolha simples e universal para que possa realizar os projetos sem preocupação com a mudança de uma plataforma para outra, sendo assim, os programas feitos no *Matlab* podem ser migrados para novas plataformas sempre que o usuário preferir.
- Funções predefinidas, a vasta biblioteca de funções predefinidas que o *software* oferece faz com que sua utilização seja ainda mais simples e intuitiva, não sendo necessário configurar ou criar fórmulas ou conceitos matemáticos básicos e também complexos para sua utilização, ganhando assim velocidade e praticidade.

- Diagramas independentes de dispositivos, como o programa é aceito em grandes variedades de plataformas, se torna notável a utilização de imagens e desenhos integrais suportadas pelo mesmo, podendo assim ser apresentado em qualquer máquina com suporte a plataforma.
- Interface gráfica de usuário, possui interface simples e interativa, onde facilita sua utilização para o usuário, com esta característica, o programador pode realizar projetos mesmo tendo baixa experiência com o programa.
- Compilador *Matlab*, o programa oferece compilações em um através da interpretação de instruções em pseudocódigo independente, assim não se torna necessário a utilização de outros programas para executar seus códigos.

Com estas características previamente apresentadas, deixa claro a grande importância que o programa possui para o meio de processamento virtual, sendo assim, utilizada como programa base para realizar diversas redes neurais artificiais.

A seguir na Figura 4.1 é mostrada a interface de rascunho à esquerda e a interface de programação do programa à direita:

Figura 4.1. Representação da interface da plataforma *Matlab*



Fonte: Autoria Própria (Versão 2020)

4.1. Desenvolvimento da Rede Neural Artificial

Será mostrado nesta etapa o desenvolvimento da Rede Neural Artificial em modelo *Adaline* através da utilização do *software Matlab R2020a*, implementando assim todo o estudo teórico realizado anteriormente.

Como o atual trabalho é uma correção e melhoria de outro feito por Carvalho e Vidotti (2017), foi mantida o modelo *Adaline*, os dados amostrais para fins de comparação são os

mesmos sendo que os valores de temperatura estão divididos por 100 e os de corrente elétrica por 10 a fim de deixar os dados na mesma grandeza numérica. Será utilizado na rede dois neurônios trabalhando em paralelo com fim de melhorar a interpretação dos dados de entrada e possibilitar o ajuste automático das variáveis para quando o sistema se estabiliza e volta as suas configurações nominais.

A implementação das etapas do código da rede neural proposta por (SILVA *et al.*, 2016) será representada a seguir:

- 1º- Obtendo as variáveis de entrada para o treinamento;
- 2º- Definir qual será a saída desejada para cada uma das variáveis;
- 3º- Definir os pesos sinápticos com pequenos valores aleatórios, a fim de melhorar a precisão do algoritmo;
- 4º- Definir a taxa de aprendizagem para a rede neural e especificar o erro requerido do sistema;
- 5º- Definir a variável de contagem de épocas inicialmente em zero, representando um momento nulo;
- 6º- Realizar repetições para os seguintes passos:
 - 6.1º- Erro Quadrático Médio anterior recebe o novo valor de Erro Quadrático Médio;
 - 6.2º- Efetuar as seguintes operações para os dados amostrais:
 - 6.2.1º- Realizar o somatório do combinador linear;
 - 6.2.2º- Atualizar os pesos sinápticos;
 - 6.3º- Incrementar o valor de época;
 - 6.4º- O valor do Erro Quadrático Médio Inicial recebe o novo valor de Erro Quadrático Médio gerado;
- 7º- Repetir os passos até que o módulo da diferença entre o Erro Quadrático Médio Atual e o Anterior seja menor que o erro especificado ou até que a contagem de épocas atinja o valor especificado.

A regra Delta é o principal motivo que permite a melhoria da precisão da rede neural, seu ajuste é definido pela minimização do Erro Médio Quadrático, que segundo a proposta de (SILVA *et al.*, 2016) fica definida da seguinte forma:

- 1º- Quantificar os padrões de treinamento;
- 2º- Iniciar o Erro Quadrático Médio com valor igual a zero;
- 3º- Repetir os seguintes passos para os dados amostrais:

3.1º- O somatório do combinador linear recebe a matriz transpostas de pesos sinápticos multiplicados pelas variáveis de entrada;

3.2º- Atualizar o Erro quadrático Médio de forma que ele receba o novo Erro Quadrático Médio somado com a diferença ao quadrado entre a matriz dos valores de saída desejados e o potencial de ativação;

4º- Por final o último valor do Erro Quadrático Médio recebe o Valor Anterior dividido pela quantidade de variáveis de entrada do sistema.

Assim, as saídas dos neurônios serão definidas através do polarizador e será associado a uma entrada fixa pelos valores em degrau -1 e 1.

Os dados amostrais foram obtidos por Carvalho e Vidotti (2017) através de testes práticos utilizando medidor de corrente e sensor de temperatura em motores trifásicos, forçando situações adversas com freios para os motores, elevando assim sua temperatura e corrente elétrica.

Em anexo se encontra o algoritmo criado e utilizado para a realização da simulação, através dele é possível demonstrar a seguinte Tabela 4.1 com os 16 dados amostrais para temperatura e corrente elétrica utilizados para gerar este estudo, juntamente com as respostas esperadas e as respostas dadas pelas Redes Neurais Artificiais.

Tabela 4.1. Representação da simulação realizada.

Dados amostrais para validação das RNA's					
Temperatura	Resposta esperada	Resposta da Rede	Corrente	Resposta esperada	Resposta da Rede
0,2526	1	1	0,6200	-1	-1
0,2842	1	1	0,2670	1	1
0,3012	1	1	0,1110	1	1
0,3357	-1	-1	0,6480	-1	-1
0,3870	-1	-1	0,0280	1	1
0,4014	-1	-1	0,3160	1	1
0,3748	-1	-1	0,5360	-1	-1
0,3920	-1	-1	0,4040	-1	-1
0,3615	-1	-1	0,2210	1	1
0,3247	1	1	0,2670	1	1
0,3712	-1	-1	0,4810	-1	-1
0,3448	-1	-1	0,3880	-1	-1
0,2998	1	1	0,1680	1	1
0,3087	1	1	0,2450	1	1
0,3745	-1	-1	0,1860	1	1
0,3920	-1	-1	0,3040	1	1

Fonte: Autoria Própria

Obtendo estes dados, podemos perceber que cada neurônio irá identificar de forma distinta cada saída para as grandezas relacionadas, não tendo uma relação direta como quando

comparado à Tabela 4.2 experimentos realizado anteriormente em sua titulada tabela 5.3 por Carvalho e Vidotti (2017).

Tabela 4.2. Terceira tentativa com 100% de acertos.

Dados amostrais para validação das RNA's			
Temperatura	Corrente	Resposta esperada	Resposta da Rede
0,2526	0,6200	-1	-1
0,2842	0,2670	1	1
0,3012	0,1110	1	1
0,3357	0,6480	-1	-1
0,3870	0,0280	1	1
0,4014	0,3160	1	1
0,3748	0,5360	-1	-1
0,3920	0,4040	-1	-1
0,3615	0,2210	1	1
0,3247	0,2670	1	1
0,3712	0,4810	-1	-1
0,3448	0,3880	-1	-1
0,2998	0,1680	1	1
0,3087	0,2450	1	1
0,3745	0,1860	1	1
0,3920	0,3040	1	1

Fonte: (CARVALHO; VIDOTTI, 2017, p. 30 – Tabela 5.3).

5 CONCLUSÃO

Neste trabalho foi estudado que a variação da temperatura e corrente elétrica nominal de funcionamento de uma máquina elétrica trifásica pode interferir diretamente no tempo de sua vida útil. Dessa maneira, ao se utilizar duas Redes Neurais Artificiais distintas trabalhando em paralelo, cada uma responsável por uma grandeza (Temperatura e Corrente Elétrica), podemos ter um monitoramento e controle mais confiáveis e precisos, tendo em vista todos os momentos de operação durante as possíveis variações e após o sistema se normalizar, avisando assim, sempre em tempo real o estado atual da máquina para o operador.

Observou-se que o desenvolvimento das RNA's em âmbito teórico, se tornou o maior desafio, pois se torna necessário o desenvolvimento do código para casos globais e/ou genéricos, para que possa ser possível se utilizar em qualquer caso ou máquina, sendo necessário apenas pequenos ajustes simples.

Evidencia-se que o propósito desta pesquisa não é comparar a utilização das RNA's com modelos de monitoramento e proteção já existentes, mas sim, verificar e estudar o comportamento de como a rede neural atua no sistema de monitoramento aplicando o modelo *Adaline*.

Para futuros projetos, se torna imprescindível a aplicação direta em máquinas trifásicas, onde, além de monitorar o estado, as duas RNA's irão identificar o problema e enviar sinais para que seja realizado a correção autônoma através da utilização de contadores para o problema ocorrido.

6 REFERÊNCIAS BIBLIOGRÁFICAS

CARVALHO, Jonathan Morais.; VIDOTTI, Guilherme Henrique Fontana. **Utilização de RNA na verificação de problemas em motores indução trifásicos**. 2018. 34 f. Trabalho de Conclusão de Curso, - Instituto Federal de Educação, Ciência e Tecnologia de Goiás, Jataí, 2017.

"Células nervosas" em **Só Biologia. Virtuoso Tecnologia da Informação**, 2008-2022. Disponível em: <https://www.sobiologia.com.br/conteudos/FisiologiaAnimal/nervoso2.php>. Consultado em 05/01/2022.

CHAPMAN, Stephen J. **Fundamentos de máquinas elétricas**. 5. Ed. Porto Alegre: AMGH, 2013.

CHAPMAN, Stephen J. **Programação em MATLAB Para Engenheiros**. 2. Ed. São Paulo: Pioneira Thomson Learning, 2003.

FITZGERALD, A. E. et al. **Máquinas Elétricas com introdução à eletrônica de potência**. 7. Ed. Porto Alegre: AMGH, 2014.

HAYKIN, Simon S.; VAN VEEN, Barry. **Sinais e sistemas**. Bookman, 2001.

KANDEL, Eric R. et al. **Princípios de Neurociências**. 5. Ed. Porto Alegre: AMGH, 2014.
Matlab, Software, versão 2020.

MAMEDE FILHO, J. **Instalações Elétricas Industriais**. 9.Ed. Rio de Janeiro: LTC, 2017.

SILVA, IVAN NUNES DA; SPATTI, DANILO HERNANE; FLAUZINO, R. A. **Redes neurais artificiais: para engenharia e ciências aplicadas**. 2. Ed. São Paulo: Artliber Editora Ltda, 2016.

7 ANEXO

Segue em anexo o código desenvolvido em *Matlab* para a realização deste trabalho:

```

ENTRADA1=[0.2526; 0.2842; 0.3012; 0.3357; 0.3870; 0.4014; 0.3748; 0.3920; 0.3615;
0.3247; 0.3712; 0.3448; 0.2998; 0.3087; 0.3745; 0.3920];
ENTRADA2=[0.6200; 0.2670; 0.1110; 0.6480; 0.0280; 0.3160; 0.5360; 0.4040; 0.2210;
0.2670; 0.4810; 0.3880; 0.1680; 0.2450; 0.1860; 0.3040];

SAIDA1=[1; 1; 1; -1; -1; -1; -1; -1; 1; -1; -1; 1; 1; -1; -1];
SAIDA2=[-1; 1; 1; -1; 1; 1; -1; -1; 1; 1; -1; -1; 1; 1; 1];

WO1=ENTRADA1;% Entradas Neurônio 1.

WO2=ENTRADA2;% Entradas Neurônio 2.

D1=SAIDA1; % Saida desejada Temperatura.
D2=SAIDA2; % Saida desejada Corrente Elétrica.

[m,n]=size(WO1); % Identifica o tamanho da matriz.

teta=ones(m,1)*(-1); %Insere o limiar de ativação.

X1=[teta,WO1]; %Define matriz para cálculo Neurônio 1.

X2=[teta,WO2]; %Define matriz para cálculo Neurônio 2.

epoca=0; % Contador de épocas zerado.

N=0.0005; % Define a taxa de aprendizado.

W1=(rand((n+1),1)); % Gerador de pesos iniciais aleatórios Neurônio 1.

W2=(rand((n+1),1)); % Gerador de pesos iniciais aleatórios Neurônio 2.

aux=1; % Critério de parada.

E=0; %Define erro inicial como zero.

while aux~=0 && epoca<100000 %Loop para cálculo da rede.

    u1=X1*W1; % Multiplicação das entradas sobre os pesos Neurônio 1.

    u2=X2*W2; % Multiplicação das entradas sobre os pesos Neurônio 2.

    for i=1:m % Define uma iteração para cada amostra proposta em cada Neurônio.

        if u1(i)>0 % Função degrau para 1.

```

```

d1(i)=1;
end

if u2(i)>0 % Função degrau para 1.

d2(i)=1;
end

if u1(i)==0 % Função degrau para 1.

d1(i)=0;

end

if u2(i)==0 % Função degrau para 1.

d2(i)=0;

end

if u1(i)<0 % Função degrau para -1.

d1(i)=-1;

if u2(i)<0 % Função degrau para -1.

d2(i)=-1;

end

end

Eqm1=0; %Define erro quadrático médio como 0 para o Neurônio 1.

Eqm2=0; %Define erro quadrático médio como 0 para o Neurônio 2.

for i=1:m %Define uma iteração para cada amostra proposta.

Eqm1=Eqm1+(D1(i)-u1(i))^2; %Cálculo do erro quadrático médio Neurônio 1.

Eqm2=Eqm2+(D2(i)-u2(i))^2; %Cálculo do erro quadrático médio Neurônio 2.

end

Ean1=Eqm1/m; % Média de valores gerados no cálculo do EQM Neurônio 1.

Ean2=Eqm2/m; % Média de valores gerados no cálculo do EQM Neurônio 2.

```

$W1=W1+(N*(D1-u1)'*X1)'$; % Correção do valor do peso para aproximação com o resultado desejado Neurônio 1.

$W2=W2+(N*(D2-u2)'*X2)'$; % Correção do valor do peso para aproximação com o resultado desejado Neurônio 2.

$u1=X1*W1$; % Multiplicação das entradas sobre os pesos Neurônio 1.

$u2=X2*W2$; % Multiplicação das entradas sobre os pesos Neurônio 2.

for i=1:m % Define uma iteração para cada amostra proposta.

if $u1(i) \geq 0$ % Função degrau para 1, no caso quando $u1(i)$ for maior que 0 atribui o valor de 1 para $d1(i)$

$d1(i)=1$;

end

if $u1(i) < 0$ % Função degrau para -1.

$d1(i)=-1$;

end

if $u2(i) \geq 0$ % Função degrau para 1, no caso quando $u2(i)$ for maior que 0 atribui o valor de 1 para $d2(i)$

$d2(i)=1$;

end

if $u2(i) < 0$ % Função degrau para -1.

$d2(i)=-1$;

end

end

epoca = epoca+1;

end

end

disp("Valores polarizados da resposta do Neurônio 1");

d1

disp("Valores polarizados da resposta do Neurônio 2");

d2