

APLICAÇÃO DE REDES NEURAIIS PARA ESTIMADORES DE VELOCIDADE SENSORLESS EM MOTORES CC NA INDÚSTRIA 4.0

Danilo Ferreira Fontoura, Wesley Candido Silva e Renato Kazuo Miyamoto*

RESUMO

O controle em malha fechada em motores de corrente contínua (CC) pode ser aplicado a sistemas industriais que necessitem de precisão e estabilidade da velocidade e da posição. Nessa metodologia de controle geralmente emprega-se sensores físicos dedicados, como *encoders* ou tacômetros. Assim, a proposta deste trabalho consiste na implementação de um estimador *sensorless* de velocidade em motores CC. Ao invés de utilizar sensores físicos dedicados, a proposta é empregar medições de corrente e tensão no motor para estimativa da velocidade, utilizando Redes Neurais Artificiais. Essa abordagem pode contribuir para a redução de custos e simplificar o projeto de controle do sistema. Para isso, foi desenvolvido o modelo matemático de um motor CC em ambiente computacional, para ser utilizado na coleta de dados e na validação cruzada. Os resultados obtidos demonstram uma precisão de 99,97% para operação em regime permanente, oferecendo um desempenho comparável aos sistemas que utilizam sensores tradicionais.

Palavras-chave: Estimador velocidade; MCC, Perceptron Multicamadas.

Implementation of a Sensorless Speed Estimator for DC Motor Using Artificial Neural Networks

ABSTRACT

Closed-loop control in direct current (DC) motors can be applied to industrial systems that require precision and stability in speed and position. In this control methodology, dedicated physical sensors, such as encoders or tachometers, are generally used. Thus, the proposal of this work consists of implementing a sensorless speed estimator for DC motors. Instead of using dedicated physical sensors, the approach is to employ current and voltage measurements in the motor to estimate speed using Artificial Neural Networks. This approach can help reduce costs and simplify the control system design. To achieve this, the mathematical model of a DC motor was developed in a computational environment to be used for data collection and cross-validation. The obtained results demonstrate an accuracy rate of 99.97% for steady-state operation, offering performance comparable to systems that use traditional sensors.

Key-words: Speed estimator; DC motor, Multilayer Perceptron.

* Autor correspondente (e-mail): renato.miyamoto@sistemafiep.org.br

1. INTRODUÇÃO

A indústria tem testemunhado um avanço significativo na automação e no controle de sistemas, impulsionado principalmente pelo desenvolvimento de novas tecnologias e técnicas de inteligência artificial (IA). Dentre os diversos elementos empregados na automação industrial, os motores elétricos, em particular os motores de corrente contínua (CC), destacam-se por sua versatilidade e ampla aplicação em vários setores, sendo utilizados em diversas aplicações industriais, especialmente em situações que exigem controle preciso de velocidade e torque (CHAPMAN, 2013).

Em sistemas de impressão e processamento de papel, a utilização de motores CC pode contribuir na sincronização e na qualidade do processo. Em sistemas de tração elétrica, como trens e veículos industriais, são valorizados pelo alto torque em baixas velocidades. Os motores CC também são encontrados em máquinas-ferramenta e CNCs, essenciais para operações de usinagem precisas, além de extrusoras na indústria de plásticos e borracha, onde controlam a qualidade do produto final. Na robótica e automação, motores CC permitem o controle exato de posição e velocidade em braços robóticos, destacando-se pela precisão e flexibilidade operacional (FERREIRA et al., 2015)

O controle de velocidade desses motores pode ser realizado de duas formas: em malha aberta (MA) e em malha fechada (MF). No controle de malha aberta, a velocidade é ajustada diretamente pela variação da tensão aplicada ao motor, sem retorno de informação. Embora seja simples e econômico, esse controle pode ser impreciso, uma vez que não há correção em caso de variações de carga, o que pode causar desvios na velocidade. No controle de malha fechada clássico, por outro lado, um sistema de *feedback* monitora a velocidade do motor utilizando sensores, como encoders ou tacômetros. Esse retorno é comparado ao valor desejado, e o controlador ajusta automaticamente a tensão para corrigir qualquer diferença, garantindo maior precisão e estabilidade, mesmo com variações de carga. O controle em malha fechada é mais utilizado em situações que exigem um controle extremamente preciso e confiável (OGATA, 2011).

Desta forma, o controle de velocidade em malha fechada apresenta várias vantagens em comparação ao controle em malha aberta, especialmente em aplicações que demandam precisão e confiabilidade. Uma das principais vantagens é a capacidade de monitorar continuamente a velocidade do motor e realizar ajustes em tempo real. Para implementar o controle em malha fechada, é comum o uso de sensores físicos, como encoders, que fornecem informações precisas sobre a posição e a velocidade do motor. Essa realimentação constante melhora a precisão do controle e assegura que o motor opere de forma eficiente, reduzindo o risco de superaquecimento ou falhas mecânicas. No entanto, esses sensores podem ser dispendiosos, o que aumenta o custo de implementação do sistema (OGATA, 2011).

Assim, a principal motivação deste trabalho consiste na implementação de um estimador *sensorless* de velocidade em motores CC. Ao invés de utilizar sensores físicos dedicados, como encoders ou tacômetros, a proposta consiste em empregar medições de corrente e tensão no motor para estimar a variável velocidade, utilizando Redes Neurais Artificiais. Essa abordagem pode contribuir para a redução de custos e simplificar o projeto de controle do sistema, oferecendo um desempenho comparável aos sistemas que utilizam sensores tradicionais. Assim, espera-se que os resultados obtidos possam contribuir para o avanço das técnicas de estimação e controle de motores CC, oferecendo uma ferramenta eficiente para engenheiros e pesquisadores na área.

A pesquisa foi realizada em etapas, e iniciou-se pela modelagem matemática do motor CC, onde foram definidas as equações dinâmicas que descrevem seu comportamento. Em seguida, essa modelagem foi implementada computacionalmente utilizando o ambiente MATLAB/Simulink, permitindo simular o sistema e gerar dados necessários. Posteriormente, foi realizada a aquisição de um banco de dados do motor sob diferentes condições de operação. Esses dados foram utilizados para treinar uma Rede Neural Artificial.

Por fim, foi realizada a validação cruzada utilizando dados não treinados pela rede, que foram obtidos a partir das aquisições computacionais realizadas

previamente no MATLAB/Simulink. A seguir, são apresentados os aspectos relacionados ao estado da arte, utilizados nessa pesquisa.

2. FUNDAMENTAÇÃO TEÓRICA

A modelagem matemática de motores de corrente contínua (CC) pode contribuir para a compreensão sobre seu comportamento dinâmico em diversas aplicações. Devido à sua capacidade de proporcionar controle preciso de velocidade e torque, é importante analisar suas características elétricas e mecânicas. Utilizando princípios como a lei de Kirchhoff e parâmetros relacionados à resistência e indutância, a transformada de Laplace e as funções de transferência simplificam a análise e o projeto de sistemas de controle eficientes. Esta seção aborda a formulação das equações do motor CC em excitação independente, destacando a importância da modelagem para o desenvolvimento de sistemas de controle de alta precisão.

2.1. Motor de Corrente Contínua CC

Os motores e geradores de corrente contínua destacam-se pela sua flexibilidade. Através de diferentes configurações dos enrolamentos de campo, que podem ser excitados de forma *shunt*, série, ou de maneira independente, é possível projetá-las para exibir uma vasta gama de comportamentos tanto em operações dinâmicas quanto em condições de funcionamento estável (MOHAN, 2018). Um motor de corrente contínua (CC) é um tipo de motor elétrico que converte energia elétrica em energia mecânica, utilizando corrente contínua. Existem duas configurações básicas para os motores de corrente contínua: motores com eletroímãs e com ímãs permanentes. Cada tipo possui suas características, vantagens e desvantagens, adequando-se a diferentes aplicações (CHAPMAN, 2013).

Nos motores CC com eletroímãs, o campo magnético é gerado por correntes elétricas que percorrem bobinas. Estas bobinas estão posicionadas tanto no estator

(parte fixa do motor) quanto no rotor (parte móvel). A principal vantagem dos motores com eletroímãs é a possibilidade de controle preciso sobre o campo magnético, permitindo ajustes na velocidade e no torque do motor através da variação da corrente elétrica nas bobinas. No estator, as bobinas de eletroímãs criam um campo magnético estático quando energizadas. No rotor, outra série de bobinas (ou às vezes uma única bobina denominada armadura) é alimentada por corrente elétrica através de um comutador e escovas. Esse arranjo cria um campo magnético dinâmico que interage com o campo do estator. A interação entre o campo magnético do estator e do rotor gera força sobre o rotor, fazendo-o girar (FREITAS JUNIOR; SILVA, 2018).

Nos motores CC com ímãs permanentes, os eletroímãs do estator são substituídos por ímãs permanentes. Isso elimina a necessidade de alimentação elétrica para a geração do campo magnético no estator, simplificando a construção do motor e reduzindo seu consumo de energia para a geração do campo magnético. Ao eliminar a corrente elétrica necessária para gerar o campo magnético do estator, os motores com ímãs permanentes tendem a ser mais eficientes energeticamente. A ausência de bobinas no estator simplifica a construção do motor e a ausência de escovas contribuem para uma menor necessidade de manutenção.

Nesse motor, os ímãs permanentes no estator criam um campo magnético constante. O rotor possui bobinas alimentadas por corrente através de um comutador e escovas (em versões com escovas), criando um campo magnético dinâmico que interage com o campo estático dos ímãs permanentes. A interação entre o campo magnético do ímã permanente e o campo magnético gerado no rotor resulta na rotação do rotor (UMANS, 2014).

Em contrapartida, um gerador de corrente contínua (CC) converte energia mecânica em energia elétrica através do princípio da indução eletromagnética. Assim como nos motores de corrente contínua, existem as configurações que utilizam eletroímãs ou ímãs permanentes. Ambos têm a mesma finalidade, mas operam com diferenças significativas em sua construção e aplicação. Nos geradores CC com

eletroímãs, tanto o estator quanto o rotor podem conter bobinas enroladas que funcionam como eletroímãs. A principal característica dos geradores com eletroímãs é a capacidade de controlar o campo magnético gerado, o que permite ajustar a tensão de saída do gerador. Ao ser energizado, o eletroímã do estator cria um campo magnético (FREITAS JUNIOR; SILVA, 2018).

Em alguns designs, o campo pode ser gerado pelo rotor. A energia mecânica, fornecida por uma fonte externa, como um motor a combustão ou uma turbina hidráulica, faz o rotor girar dentro do campo magnético do estator. Devido à rotação do rotor dentro do campo magnético, é induzida uma corrente elétrica nas bobinas do rotor (ou no estator, dependendo do design). A lei da indução de Faraday explica esse fenômeno, onde a variação do fluxo magnético através do enrolamento gera uma tensão elétrica. A energia elétrica gerada é coletada por meio de comutadores e escovas, sendo então direcionada para fora do gerador (UMANS, 2014).

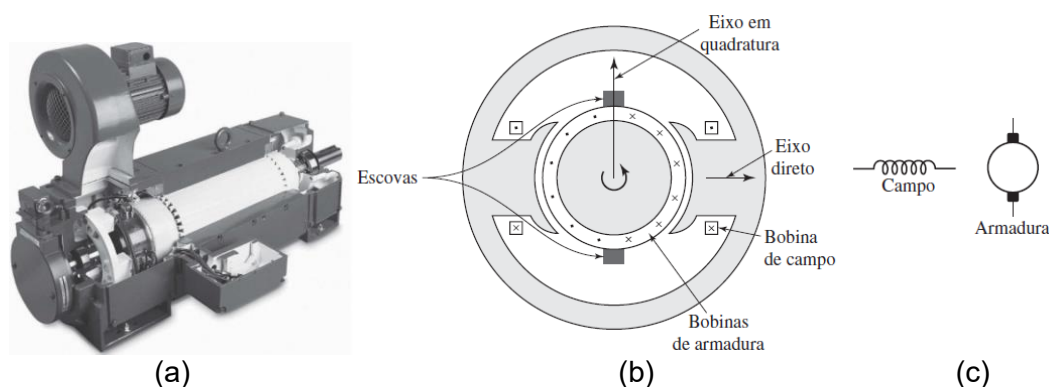
Já os geradores CC com ímãs permanentes utilizam ímãs fixos no lugar de eletroímãs para criar o campo magnético necessário para a indução de corrente elétrica. Esses geradores são tipicamente mais simples, mais compactos e têm eficiência energética melhorada em algumas aplicações, especialmente em tamanhos menores. Os ímãs permanentes fornecem um campo magnético constante. A rotação do rotor (equipado com condutores ou bobinas) dentro desse campo magnético estático induz uma corrente elétrica nos condutores. A energia elétrica induzida é extraída por meio de comutadores e escovas, assim como nos geradores com eletroímãs (FREITAS JUNIOR; SILVA, 2018).

As características fundamentais de uma máquina de corrente contínua são ilustradas de forma esquemática na Figura 1. O estator, equipado com polos salientes, é ativado por uma ou várias bobinas de campo. A distribuição do fluxo gerado pelos enrolamentos de campo no espaço entre o estator e o rotor é uniforme em torno da linha central dos polos de campo, eixo este que é conhecido como eixo de campo ou eixo direto.

A corrente alternada (CA) produzida em cada bobina da armadura rotativa é transformada em corrente contínua (CC) nos terminais externos da armadura através do uso de um comutador rotativo e escovas fixas, aos quais os condutores da armadura são conectados. Esse arranjo de comutador e escovas atua como um retificador mecânico, convertendo assim em uma tensão CC na armadura e gerando uma onda de força magneto motriz (FMM) de armadura que permanece estacionária no espaço (UMANS, 2014).

As escovas são posicionadas de tal forma que a comutação aconteça quando as bobinas se encontram na zona neutra, precisamente no meio do caminho entre os polos de campo. Assim, o eixo da onda de força magneto motriz (FMM) da armadura estará deslocado por 90 graus elétricos em relação ao eixo dos polos de campo, situando-se no eixo de quadratura. Na ilustração esquemática da Figura 1(b), as escovas são representadas posicionadas no eixo de quadratura, correspondendo à posição das bobinas às quais estão conectadas. Conseqüentemente, a onda de FMM da armadura se alinha ao longo do eixo das escovas, conforme indicado (UMNAS, 2014). Uma simplificação dessa representação, usada em diagramas de circuitos, é mostrada na Figura 1(c).

Figura 1 – Representação de uma máquina CC: (a) vista em corte longitudinal; (b) vista esquemática da MCC com comutador; (b) esquemático dos enrolamentos de campo e de armadura.




Fonte: Umans (2014, p. 404).

A tensão gerada e posteriormente retificada pela armadura pode ser observada na Figura 2. A figura ilustra o impacto da distribuição do enrolamento ao longo de

várias ranhuras, onde cada onda senoidal retificada representa a tensão produzida em uma das bobinas. O processo de comutação acontece no instante em que os lados das bobinas alcançam a zona neutra (CHAPMAN, 2013).

Figura 2 – Tensões retificadas de bobina e resultante entre as escovas de uma máquina CC.



Fonte: Umans (2014, p. 405).

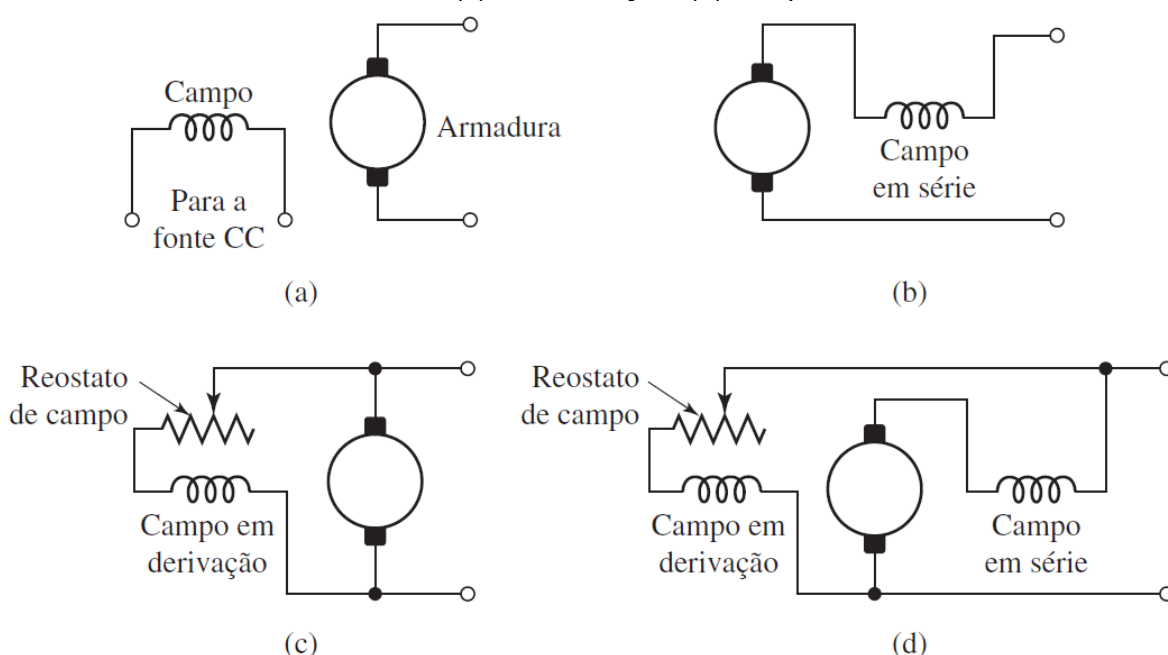
A tensão gerada que se percebe entre as escovas resulta da adição das tensões retificadas de todas as bobinas conectadas em série entre as escovas, representada pela curva ondulada e_a na Figura 2. Com aproximadamente de uma dúzia de segmentos de comutador por polo, a ondulação da tensão é significativamente reduzida, fazendo com que a tensão média detectada nas escovas seja equivalente à soma dos valores médios das tensões retificadas de cada bobina (UMANS, 2014).

As vantagens notáveis das máquinas de corrente contínua (CC) derivam da ampla gama de características operacionais que podem ser alcançadas através da seleção do método de excitação para os enrolamentos de campo. Diferentes esquemas de conexão são apresentados na Figura 3. A escolha do método de excitação tem um impacto significativo nas características de operação em estado estacionário e, em sistemas de controle, no comportamento dinâmico da máquina (UMANS, 2014).

A ligação em excitação independente em motores de corrente contínua (CC) (Figura 3(a)) é uma configuração onde a corrente de campo (ou excitação) é fornecida

por uma fonte de alimentação separada da fonte que alimenta a armadura do motor. Ou seja, o circuito de campo e o circuito de armadura são alimentados independentemente. Isso permite controlar de forma mais precisa a corrente de excitação, resultando em um controle mais flexível da velocidade e do torque do motor.

Figura 3 – Ligações do circuito de campo de máquinas CC: (a) excitação independente; (b) em série; (c) em derivação; (d) composta.



Fonte: Umans (2014, p. 407).

Em motores com excitação independente, a corrente de campo pode ser mantida constante enquanto se ajusta a tensão ou a corrente da armadura para variar a velocidade do motor. Esse tipo de controle permite uma faixa ampla de ajuste de velocidade, tornando-o particularmente útil em aplicações onde é necessária precisão no controle de velocidade e torque. Esse tipo de ligação facilita o controle de aceleração e desaceleração e melhora a resposta do motor às variações de carga.

Devido à sua capacidade de controle preciso e flexível, os motores de corrente contínua com excitação independente são amplamente utilizados em:

1. **Máquinas de corte e usinagem:** A precisão no controle da velocidade é fundamental para assegurar a qualidade e a precisão do trabalho. Em tornos, fresadoras e outras máquinas-ferramenta, o controle de velocidade proporcionado pela excitação independente é altamente vantajoso.
2. **Transportes elétricos e locomotivas:** A flexibilidade e controle de torque oferecidos pela excitação independente são ideais para sistemas de tração elétrica, que exigem variação contínua de velocidade e força de tração para diferentes condições de operação.
3. **Elevadores e guindastes:** Nessas aplicações, a capacidade de ajustar o torque e a velocidade com precisão é essencial para garantir segurança e suavidade nas operações, especialmente em situações de carga variável.
4. **Sistemas de geração e controle de energia:** Em certos sistemas de geração de energia, como grupos geradores e máquinas síncronas, motores com excitação independente são usados para controle de velocidade preciso e para garantir uma operação estável e contínua.

A excitação independente oferece um controle mais preciso sobre o desempenho do motor, proporcionando uma faixa mais ampla de controle de velocidade e torque. Esse tipo de configuração é especialmente útil em sistemas que exigem variações frequentes e rápidas de velocidade ou que operam sob condições de carga variáveis. A seguir os aspectos relacionados a modelagem matemática do motor CC em excitação independente será apresentado.

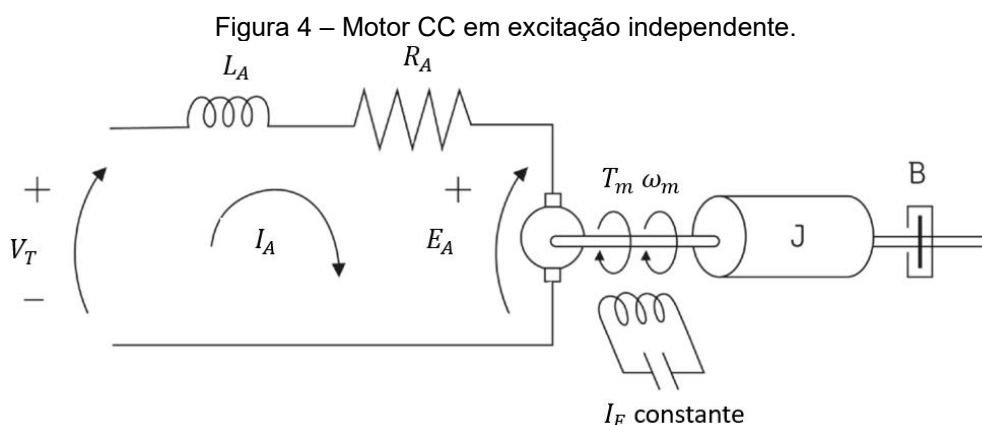
2.2. Modelo Matemático do Motor CC

Para descrever o comportamento do motor CC em excitação independente, precisamos desenvolver equações que descrevam tanto o circuito elétrico quanto o circuito magnético do motor. No circuito elétrico, usamos a lei de Kirchhoff das tensões para escrever a equação que relaciona a tensão aplicada ao motor, a queda

de tensão nos enrolamentos do campo e do induzido, e a força contraeletromotriz gerada pelo movimento do motor (MIYAMOTO, 2023).

Na modelagem do motor CC, é importante considerar parâmetros como resistência dos enrolamentos, indutância, constante de torque, constante de velocidade, coeficiente de atrito, inércia do rotor, torque de carga, entre outros. Esses parâmetros influenciam diretamente o desempenho do motor em termos de velocidade, torque, eficiência e resposta dinâmica. A validação do modelo pode ser realizada através da comparação dos resultados da simulação com dados experimentais obtidos em testes com o motor real. Podemos ajustar os parâmetros do modelo para que os resultados da simulação se aproximem o máximo possível dos dados experimentais, garantindo assim a precisão do modelo (OGATA, 2011)

A modelagem de motores CC emprega a transformada de Laplace e funções de transferência para uma análise minuciosa e controle do comportamento dinâmico desses dispositivos. Desta forma, examinaremos a modelagem da função de transferência de um servomotor de corrente contínua (CC), cujo controle é realizado através da tensão terminal, conforme ilustrado na Figura 4 (MIYAMOTO, 2023).



Fonte: Adaptado de Tavares (2017, p. 145).

Esta abordagem transforma as equações diferenciais que governam o sistema em equações algébricas mais simples no domínio da frequência, simplificando a análise de estabilidade, controle e resposta dinâmica do motor. Ao aplicar a

transformada de Laplace, variáveis como corrente do enrolamento, velocidade e torque podem ser expressas em termos de "s", a variável complexa da transformada. Aplicando a lei de Kirchhoff das tensões no circuito de armadura obtemos (TAVARES, 2017):

$$V_T(t) = L_A \frac{dI_A(t)}{dt} + R_A I_A(t) + E_A(t) \quad (1)$$

Aplicando a transformada de Laplace, lembrando que $\mathcal{L}\left\{\frac{df(t)}{dt}\right\} = sF(s)$, obtém-se (TAVARES, 2017):

$$V_T(s) = sL_A I_A(s) + R_A I_A(s) + E_A(s) \quad (2)$$

Isolando I_A obtemos (TAVARES, 2017):

$$I_A(s) = \frac{V_T(s) - E_A(s)}{L_A s + R_A} \quad (3)$$

A tensão gerada, pode ser calculada a partir de parâmetros mecânicos (CHAPMAN, 2013):

$$E_A(s) = K \cdot \omega_m(s) \quad (4)$$

em que K é uma constante construtiva do motor CC, e ω_m é a velocidade mecânica. No motor CC, o torque mecânico (T_m) pode ser calculado em função da corrente de armadura (CHAPMAN, 2013):

$$T_m(s) = K \cdot I_A(s) \quad (5)$$

O torque, no domínio do tempo, também pode ser obtido por (CHAPMAN, 2013):

$$T_m = J \cdot \frac{d\omega_m}{dt} + B\omega_m \quad (6)$$

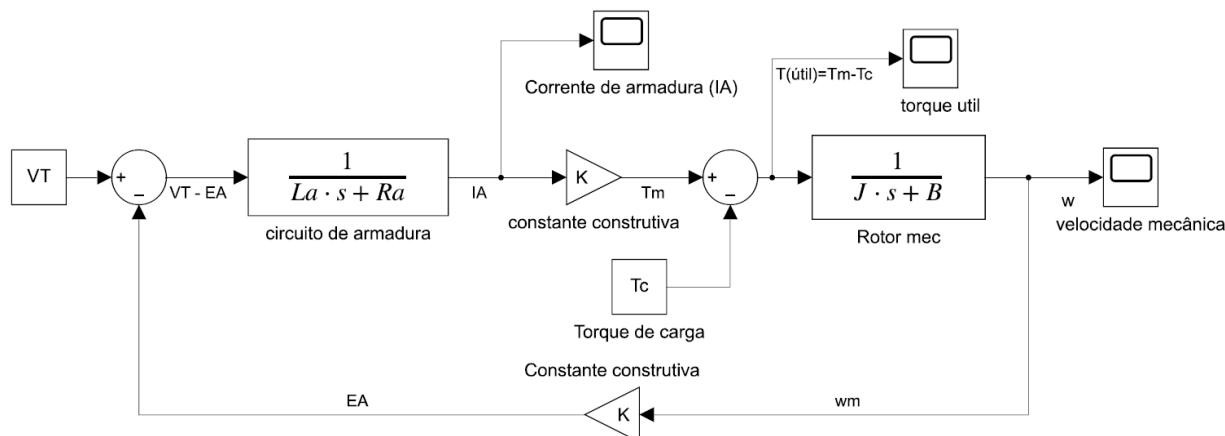
Em que J refere-se ao momento de inércia do motor e B é o coeficiente de atrito. Aplicando a transformada de Laplace, e isolando a velocidade mecânica, obtemos (TAVARES, 2017):

$$T_m(s) = \omega_m(s)(Js + B) \rightarrow \omega_m(s) = \frac{T_m(s)}{Js + B} \quad (7)$$

O conjunto de equações do motor CC pode ser agrupado no diagrama de blocos da Figura 5, que apresenta o modelo matemático em função de transferência.

Nesse modelo a entrada é a tensão terminal (V_T) e os parâmetros de saída são: corrente de armadura, torque útil e velocidade mecânica.

Figura 5 – Motor CC em diagrama de blocos de função de transferência.



Fonte: Elaborado pelos autores.

Por meio dessas etapas, podemos desenvolver um modelo matemático preciso e confiável do motor CC em excitação independente, que pode ser utilizado para projetar e otimizar sistemas que utilizam esse tipo de motor.

2.3. Controle de velocidade *Sensorless*

O controle de velocidade *sensorless*, que elimina a necessidade de sensores físicos dedicados para medir a velocidade ou a posição do rotor, podendo se utilizar de medidas indiretas ou algoritmos de aproximação. Essa técnica é amplamente utilizada em motores elétricos, como os de corrente contínua (CC) e corrente alternada (CA). Essa abordagem é vantajosa em aplicações onde a instalação de sensores é desafiadora, ajudando a reduzir custos e aumentar a confiabilidade do sistema (CHAPMAN, 2013).

Uma das principais características do controle *sensorless* é o uso de modelos matemáticos do motor para estimar a velocidade e a posição do rotor. Essa estimativa baseia-se em parâmetros como resistência, indutância e torque. Métodos como observadores de estado, incluindo o observador de Kalman e o observador de

Luenberger, são frequentemente utilizados para calcular a velocidade a partir de outras variáveis do motor, como corrente e tensão (OGATA, 2011).

As vantagens do controle *sensorless* incluem a redução de custos com *hardware*, aumento da confiabilidade do sistema e um *design* mais compacto, com menos componentes eletrônicos, diminuindo os pontos de falha (CARVALHO, 2011). No entanto, os desafios permanecem: a precisão pode ser comprometida em condições de carga variável ou em motores com características indefinidas. Alterações na carga e nas características do motor podem afetar negativamente a precisão das estimativas (MIYAMOTO, 2023).

O *sensorless* é aplicado em acionamentos de ventiladores, bombas e transportadores, sendo ideal em situações em que o espaço é limitado ou onde é necessária proteção contra ambientes hostis (HAYKIN, 2001).

Essa área de pesquisa continua a evoluir, com avanços em algoritmos de estimação e a integração de inteligência artificial e aprendizado de máquina, prometendo aprimorar a precisão e robustez dos sistemas *sensorless* em diversas aplicações industriais (HAGAN; DEMUTH; BEALE, 1996).

2.4. Redes Neurais Artificiais

A aplicação de redes neurais artificiais, como o Perceptron Multicamadas (PMC), em simulações de motores de corrente contínua (CC) tem ganhado destaque devido à sua capacidade de aproximar funções complexas e prever comportamentos não lineares. Nesta seção, exploraremos os conceitos fundamentais das redes neurais, em especial o PMC, e a sua aplicação em simulações de motores CC, conforme estabelecido pela literatura.

As redes neurais artificiais (RNA) são sistemas computacionais inspirados na estrutura e no funcionamento do cérebro humano. De acordo com HAYKIN (2001), uma rede neural é composta por neurônios artificiais organizados em camadas: camada de entrada, camadas ocultas e camada de saída. Cada neurônio é interconectado através de pesos que são ajustados durante o processo de

treinamento da rede. O aprendizado da rede neural é realizado por meio de algoritmos de aprendizado supervisionado ou não supervisionado.


A aplicação de redes neurais artificiais, como o Perceptron Multicamadas (PMC), são caracterizadas pela presença de menos uma camada intermediária escondida de neurônios situada entre a camada de entrada e a respectiva camada neural de saída (SILVA; SPATTI; FLAUZINO, 2010).

2.4.1. Perceptron Multicamadas (PMC)

A modelagem de sistemas dinâmicos, como motores elétricos, pode se beneficiar significativamente do uso de RNAs, especialmente do PMC, devido à sua capacidade de lidar com a não-linearidade e variabilidade dos dados. Conforme exposto por Haykin (2001), as RNAs são particularmente eficazes na modelagem de sistemas onde a relação entre as variáveis de entrada e saída é complexa e não pode ser facilmente capturada por métodos tradicionais (HAYKIN, 2001).

O PMC é uma das arquiteturas de RNA mais utilizadas devido à sua capacidade de aprendizado e generalização. Segundo Haykin (2001), o PMC consiste em uma camada de entrada, uma ou mais camadas ocultas e uma camada de saída, conforme se observa na Figura 6.

Figura 6 – Estrutura de uma PMC com duas camadas escondidas.



Fonte: (SILVA; SPATTI; FLAUZINO, 2010).

Cada camada é composta por um conjunto de neurônios, onde cada neurônio da camada anterior está conectado a todos os neurônios da camada subsequente. O processo de treinamento do PMC é realizado através do algoritmo de retropropagação, que ajusta os pesos das conexões minimizando o erro entre a saída prevista e a saída desejada.

2.4.2. Algoritmos de Treinamento

Conforme descrito por Silva, Spatti e Flauzino (2010), a presença de camadas ocultas permite ao PMC capturar relações não lineares nos dados, aumentando significativamente sua capacidade de modelagem e predição.

Os algoritmos de treinamento são de grande relevância para o desempenho das redes neurais. O algoritmo de retropropagação é o mais comum para PMCs, mas existem outras variações e métodos, como o algoritmo de Levenberg-Marquardt, que oferece um equilíbrio entre a descida gradiente e a otimização de Gauss-Newton, proporcionando uma convergência mais rápida em muitos casos (HAGAN, DEMUTH e BEALE, 1996). A escolha do algoritmo pode influenciar significativamente a eficiência e a precisão da rede.

2.4.3. *Overfitting* e Técnicas de Regularização

O *overfitting* ocorre quando a rede neural se ajusta excessivamente aos dados de treinamento, perdendo a capacidade de generalizar para novos dados. Para combater o *overfitting*, diversas técnicas de regularização podem ser aplicadas, como o *dropout*, a normalização L2 e a *early stopping*. *Dropout*, por exemplo, desativa aleatoriamente neurônios durante o treinamento, forçando a rede a aprender representações mais robustas e evitando a dependência de neurônios específicos (SRIVASTAVA et al., 2014).

2.4.4. Validação Cruzada

A validação cruzada é uma técnica estatística utilizada para avaliar a capacidade de generalização de um modelo. Segundo Hastie, Tibshirani e Friedman (2009), a validação cruzada k-fold é uma abordagem comum, onde os dados são divididos em k subconjuntos, e o modelo é treinado k vezes, cada vez utilizando um subconjunto diferente como conjunto de validação. Isso permite uma estimativa mais robusta da performance do modelo em dados não vistos.

3. METODOLOGIA

Nesta seção será apresentado os aspectos metodológicos utilizados neste trabalho para a implementação de uma rede neural artificial capaz de estimar a velocidade de um motor de corrente contínua.

3.1. Aplicação de PMC em Simulações de Motores CC

Os motores de corrente contínua (CC) são amplamente utilizados em diversas aplicações industriais devido à sua simplicidade e facilidade de controle. A simulação do comportamento desses motores é requerida para o desenvolvimento de sistemas de controle eficientes e, com o uso da rede PMC, pode proporcionar uma aproximação precisa do comportamento do motor. Assim, foi realizado um processo de desenvolvimento de um sistema de estimativa de parâmetros para um motor elétrico, utilizando modelagem matemática, simulação no MATLAB/Simulink e redes neurais artificiais (RNA).

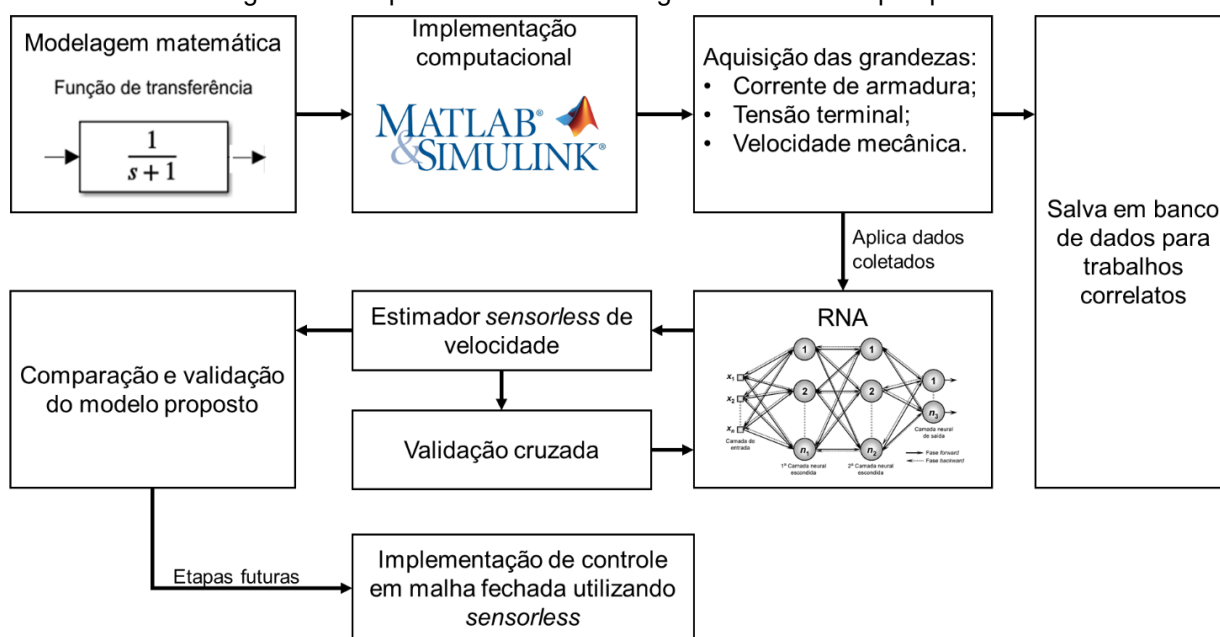
Para usar a PMC aplicada a um estimador de velocidade de motor CC foi necessário fazer a coleta de dados de entrada (como tensão e corrente) e saída (velocidade do motor). Esses dados são utilizados para treinar a rede neural, que aprende a relação entre as entradas e a saída do sistema. Após o treinamento, a rede

pode ser utilizada para prever o comportamento do motor sob diferentes condições de carga e operação.

A Figura 7 ilustra os aspectos metodológicos deste trabalho. A primeira etapa envolve a modelagem matemática do sistema, representada por uma ou mais funções de transferência, que descrevem o comportamento dinâmico do motor. Essa modelagem é implementada computacionalmente no *software* MATLAB/Simulink, permitindo simular o funcionamento do motor e analisar suas respostas dinâmicas.

Durante a simulação, são adquiridos dados fundamentais como a corrente de armadura, a tensão no terminal e a velocidade mecânica do motor. Esses dados são então utilizados em um estimador de velocidade *sensorless*, ou seja, um método que estima a velocidade sem o uso de sensores físicos, baseando-se nos parâmetros elétricos e no modelo do motor.

Figura 7 – Esquemático da metodologia utilizada nesta pesquisa.



Fonte: Elaborado pelos autores.

Os dados adquiridos são aplicados a uma Rede Neural Artificial (RNA) com a arquitetura Perceptron Multicamadas (PMC), que é treinada para aprender o comportamento do motor. A RNA é capaz de prever a velocidade ou outros


parâmetros importantes a partir dos dados de entrada. Para garantir a precisão do modelo treinado, é realizada uma validação cruzada, comparando as previsões da RNA com os dados reais para verificar sua acurácia.

Após essa etapa, o modelo proposto é comparado e validado para garantir que representa corretamente o comportamento do motor. Os dados coletados, juntamente com os resultados da simulação e da RNA, são armazenados em um banco de dados, permitindo o uso desses dados para trabalhos futuros e análises correlatas.

3.1.1. Coleta de Dados e Treinamento

A coleta de dados é uma das etapas mais importantes na aplicação de PMC, para isso foi utilizado a ferramenta Simulink do Matlab, que permite a simulação de sistemas dinâmicos, por meio de blocos prontos que representam o funcionamento de um motor ou por blocos de modelagem matemática que representem esse comportamento. Para o trabalho proposto, foi utilizado um diagrama de modelagem matemática que simula um motor CC (Figura 8).

Figura 8 – Diagrama Simulink da implementação computacional da MCC.



Fonte: Elaborado pelos autores.

Aplicando as Leis de Newton, o sistema mecânico rotacional pode ser representado matematicamente por funções de transferências (OGATA, 2010). A

Tabela 1 apresenta os parâmetros elétricos e mecânicos da MCC simulada nessa pesquisa.

Tabela 1 – Parâmetros do circuito equivalente.


Parâmetro	Valor
Resistência de armadura (R_a)	2Ω
Indutância de armadura (L_a)	0,01H
Constante condutiva (K)	0,32
Momento de inércia (J)	$0,01 \text{ kg}\cdot\text{m}^2$
Coeficiente de atrito (B)	$0,01 \text{ N}\cdot\text{m}/\text{rad}/\text{s}$
Tensão terminal nominal (VT)	220V
Torque de carga (T_c)	0

Fonte: Elaborado pelos autores.

Durante a simulação, são coletados valores de tensão terminal de armadura (VT), corrente de armadura (I_a) e velocidade do motor (ω). Esses dados são multiplexados e enviados para a *workspace* do Matlab. A cada simulação, foi alterado o valor da tensão terminal de armadura (VT) e os dados coletados foram organizados em uma única tabela aplicada para o treinamento da rede neural. Na Figura 9, observa-se que foram alteradas as tensões terminais da armadura em quatro valores distintos: 220 V, 198 V, 176 V e 154 V.

Essas mudanças de tensão influenciaram tanto a corrente de armadura (I_a), quanto a velocidade do motor. Observa-se que a redução gradual da tensão terminal provoca uma diminuição tanto na corrente quanto na velocidade, refletindo o comportamento dinâmico do motor de corrente contínua em resposta às alterações de tensão.

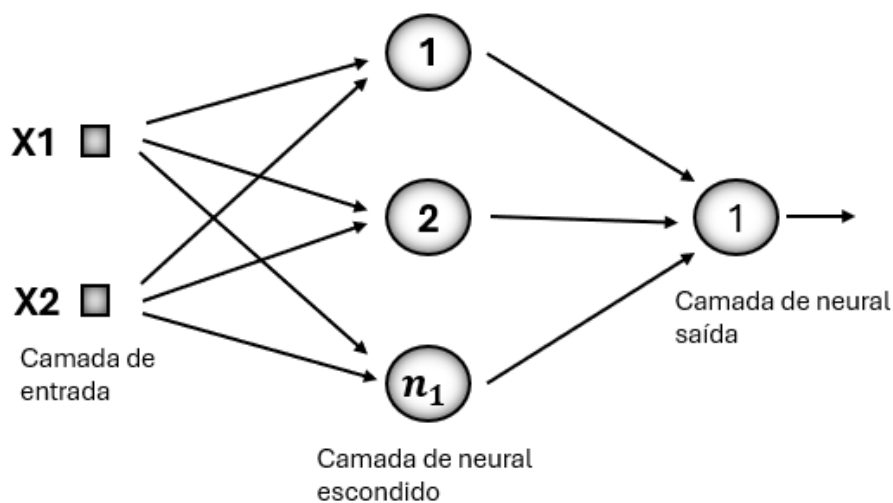
Figura 9 – Coleta de dados para treinamento da RNA.



Fonte: Elaborado pelos autores.

Com os valores obtidos, foi utilizado um *script* no MatLab que emprega uma rede neural PMC por aproximação. O treinamento pode exigir elevado processamento computacional, especialmente para redes com muitas camadas e neurônios e dependendo da taxa de aprendizagem e precisão aplicados. A topologia genérica da PMC proposta neste trabalho está ilustrado na Figura10.

Figura 10 – Topologia genérica da PMC.



Fonte: Elaborado pelos autores.

Na figura, X_1 e X_2 são as entradas da rede: tensão terminal de armadura (VT) e corrente de armadura (I_a) normalizados para pu; n_1 é o número de neurônios da camada escondida e a velocidade do motor (ω) é a saída da rede normalizada em pu.

3.1.2. Validação e Resultados

Após o treinamento, a rede PMC deve ser validada para verificar sua capacidade de generalização. Segundo Haykin (2001), a validação pode ser realizada utilizando um conjunto de dados que não foi utilizado durante o treinamento. A saída prevista pela rede é comparada com a saída real para avaliar a precisão do modelo.

Da mesma forma que na tabela de dados, foi feito a coleta dos valores de entradas e saída multiplexados em uma única tabela, porém, a tabela de validação recebe um nome diferente, pois é usada em etapas diferentes.

Ao obter o gráfico das curvas, é possível notar a eficiência da rede através das duas linhas que são geradas. Como forma de ajuste da rede neural em busca de um melhor resultado, alguns parâmetros foram ajustados, a saber: valores de números de neurônios, taxa de aprendizagem e precisão do sistema, fazendo com que a rede demore mais ou menos para treinar e obtenha resultados mais próximos do esperado.

No contexto de simulação de motores CC, a validação pode ser realizada comparando a saída da rede (velocidade prevista) com os dados coletados do Simulink.


4. APRESENTAÇÃO E DISCUSSÃO DOS RESULTADOS

Nesta seção, serão apresentados e discutidos os resultados obtidos com a aplicação de Redes Neurais Artificiais (RNA) para estimar a velocidade de um motor de corrente contínua (CC). Foram realizados três ensaios distintos, variando o número de neurônios na camada de entrada da rede: i) com 15 neurônios, ii) com 17 neurônios e iii) com 20 neurônios. A escolha dessas configurações permitiu avaliar o impacto do

número de neurônios na precisão das estimativas de velocidade, bem como identificar o modelo mais adequado para a previsão dessa variável. Os resultados obtidos serão analisados considerando a eficácia de cada configuração em termos de precisão e capacidade de generalização da rede.

Para o ensaio 1, a rede neural utilizada, com 15 neurônios na entrada, estimou a velocidade do motor com alta precisão, obtendo uma saída de 0,7005 pu em comparação com a velocidade esperada de 0,7000 pu, resultando em um erro muito pequeno de 0,0005 pu, que resulta em uma precisão de 99,95%. Na Figura 11, observa-se que a velocidade do motor atinge rapidamente um valor estável próximo de 0,7 pu, enquanto a estimativa da rede acompanha de perto, porém com um pequeno desvio constante evidenciado no zoom entre as amostras 3990 e 4010.

Figura 11 – Ensaio 1, para uma RNA com 15 neurônios.




Fonte: Elaborado pelos autores.

Para o ensaio 2, ilustrado na Figura 12, observa-se uma simulação da velocidade do motor e do estimador de velocidade da rede neural, configurada com 17 neurônios na entrada. A rede neural alcançou uma saída de 0,7008 pu, enquanto

a saída esperada era de 0,7000 pu, resultando em um erro pequeno de 0,0008 (e precisão de 99,92%). Esse pequeno erro residual é ilustrado no zoom entre as amostras 3990 e 4010, onde o estimador se mantém um pouco abaixo da velocidade do motor.

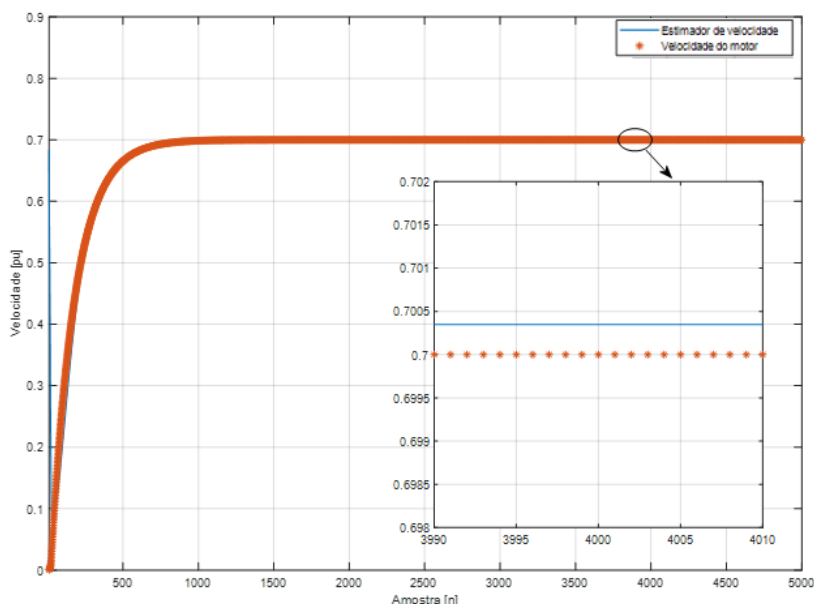
No ensaio 3, ilustrado na Figura 13, o gráfico exibe a velocidade do motor e o estimador de velocidade gerado pela rede neural. Com uma topologia de rede ajustada para 20 neurônios na entrada, a saída obtida da rede neural foi de 0,7003 pu, enquanto a saída esperada era de 0,7000 pu, indicando um erro muito pequeno de apenas 0,0003 (com precisão de 99,97%). A velocidade do motor mostra uma resposta rápida de estabilização, e o estimador acompanha essa resposta de maneira próxima, com um pequeno desvio residual visível na área ampliada entre as amostras 3990 e 4010. Esse desvio leve sugere que o modelo está bem treinado e é altamente preciso para modelar o comportamento do motor, embora ajustes finos adicionais possam ainda reduzir esse erro, caso uma precisão extrema seja necessária para a aplicação.

Figura 12 – Ensaio 2, para uma RNA com 17 neurônios.



Fonte: Elaborado pelos autores.

Figura 13 – Ensaio 3, para uma RNA com 20 neurônios.



Fonte: Elaborado pelos autores.

A aplicação de PMC em simulações de motores CC apresenta alguns desafios. A escolha dos parâmetros da rede, como o número de camadas e neurônios, pode influenciar significativamente a precisão do modelo. Além disso, o tempo de treinamento pode ser um fator limitante, especialmente para problemas complexos. A Tabela 2 sintetiza os resultados obtidos nesta pesquisa.

Tabela 2 – Resultados obtidos no estimador de velocidade sensorless

Topologia RNA	Ensaio 1	Ensaio 2	Ensaio 3
n. neurônios	15	17	20
Função de ativação	<i>Logística</i>	<i>Logística</i>	<i>Logística</i>
Taxa aprendizagem	0.008	0.008	0.008
Precisão	10^{-7}	10^{-7}	10^{-7}
Velocidade real (pu)	0,7000	0,7000	0,7000
Velocidade estimada (pu)	0,7005	0,7008	0,7003
Precisão de acerto (%)	99,95%	99,92%	99,97%

Fonte: Elaborado pelos autores.

Outro desafio é a generalização do modelo, uma rede neural bem treinada deve ser capaz de generalizar bem para dados não vistos durante o treinamento. No entanto, pode ocorrer erros no qual a rede se ajusta excessivamente aos dados de treinamento, perdendo a capacidade de generalizar, podendo-se dizer que a rede não convergiu. Como forma de melhorar o comportamento da saída da rede, foi encontrado valores de ajuste da taxa de aprendizagem e precisão que retornasse uma curva próxima do esperado.

5. CONSIDERAÇÕES FINAIS

O uso do Perceptron Multicamadas (PMC) na simulação e estimação da velocidade de motores de corrente contínua (CC) demonstrou ser uma abordagem eficaz, capaz de prever o comportamento do motor com alta precisão. Nos experimentos realizados, com diferentes configurações de rede, obteve-se uma excelente precisão de estimativa, com erros muito pequenos, variando entre 0,0003 e 0,0008 pu, resultando em uma precisão de 99,95% a 99,92% dependendo da quantidade de neurônios na camada de entrada. Esses resultados confirmam a capacidade do PMC em modelar de forma precisa sistemas dinâmicos não lineares, como os motores CC, mesmo diante de variações de carga e tensão de operação.

A análise dos resultados evidenciou que o número de neurônios na camada de entrada impacta diretamente na precisão da rede. O ensaio com 20 neurônios na entrada obteve o menor erro (0,0003 pu), sugerindo que uma maior quantidade de neurônios melhora a capacidade de previsão da rede, embora com um pequeno aumento no tempo de treinamento. A comparação entre a saída esperada e a saída prevista pelas redes neurais, visível nos gráficos das simulações, revela que o modelo PMC é capaz de seguir de forma estável e precisa as flutuações de velocidade do motor, com apenas um pequeno desvio residual.

Entretanto, a implementação do PMC em sistemas de controle de motores CC, apesar de promissora, ainda apresenta desafios, como o risco de *overfitting* e a necessidade de um treinamento adequado para garantir a generalização do modelo. A regularização e a validação cruzada, aplicadas durante a fase de treinamento, se mostraram fundamentais para mitigar esses problemas e garantir a precisão do modelo para dados não vistos. Além disso, o tempo de treinamento pode ser um fator limitante em redes mais complexas, especialmente quando o número de neurônios e camadas aumenta.

Para futuras pesquisas, propõe-se a utilização do método *sensorless* para a implementação de controle em malha fechada de motores de corrente contínua (MCC). A proposta de um controle *sensorless* em malha fechada visa eliminar a necessidade de sensores de velocidade, utilizando a estimativa de velocidade gerada pela rede neural para ajustar a operação do motor em tempo real. Esse avanço pode tornar os sistemas de controle mais robustos e econômicos, ao mesmo tempo em que aumenta a flexibilidade na adaptação a diferentes condições operacionais.

Além disso, futuras investigações podem explorar a combinação de PMC com outras técnicas de otimização, como algoritmos evolutivos ou aprendizado profundo, para melhorar ainda mais a precisão e a eficiência dos modelos. A introdução de técnicas avançadas de treinamento e otimização de hiperparâmetros também pode contribuir para a superação das limitações atuais, tornando o modelo mais eficiente e aplicável em sistemas industriais reais.

Em resumo, o uso de PMC em simulações de motores CC representa um grande avanço na modelagem e controle de sistemas elétricos, com um potencial significativo para aplicações industriais. A combinação dessa abordagem com controle *sensorless* em malha fechada poderá trazer benefícios adicionais, criando soluções mais eficazes e de baixo custo para o controle de motores elétricos.

REFERÊNCIAS

CHAPMAN, S. J. **Fundamentos de Máquinas Elétricas - 5ed.** [s.l.] AMGH Editora, 2013.

FERREIRA, J. C. et al. Construção de um sistema didático para o ensino de lógica aplicada a processos de automação - BANCADA DIDÁTICA ELEVADORES. 2015.

FREITAS JUNIOR. L. C.; SILVA, R. S. **Máquinas elétricas.** Londrina: Editora e Distribuidora Educacional S.A., 2018.

MOHAN, N. **Máquinas elétricas e acionamentos:** curso introdutório. 1.ed. Rio de Janeiro: LTC, 2018.

OGATA. **Engenharia de controle moderno** 5a ed. São Paulo: Person, 2011.

HAGAN, M.T., DEMUTH, H.B., BEALE, M.H. **Neural Network Design.** PWS Publishing, 1996.

SRIVASTAVA, N. et al. Dropout: A Simple Way to Prevent Neural Networks from Overfitting. *Journal of Machine Learning Research*, v. 15, p. 1929-1958, 2014.

HASTIE, T., TIBSHIRANI, R., FRIEDMAN, J. **The Elements of Statistical Learning.** 2ª edição. Springer, 2009.

CARVALHO, Geraldo. **Máquinas elétrica teoria e ensaios.** 4. ed. São Paulo: Erica, 2011. 260 p

HAYKIN, Simon. **Redes neurais.** 2. ed. Porto Alegre: Bookman, 2001. 900 p

MIYAMOTO, R. K. **Notas de aula: Inteligência Artificial Aplicada em Automação.** Londrina: 2024.

MIYAMOTO, R. K. **Notas de aula: Modelagem de sistemas mecânicos rotacionais.** Londrina: 2023.

TAVARES, M. F. **Modelagem de sistemas dinâmicos.** 1.ed. Londrina: Editora e Distribuidora Educacional S.A., 2017.

SILVA, Iyan Nunes; SPATTI, Danilo Hernane; FLAUZINO, Rogerio Andrade. **Redes neurais artificiais.** 1. ed. São Paulo: Artliber, 2010. 399 p



Esta obra está licenciada com Licença Creative Commons Atribuição-Não Comercial 4.0 Internacional.
[Recebido/Received: Dezembro 18 2024; Aceito/Accepted: Janeiro 29, 2025]