

E-TEC

Revista de Tecnologia e Ciência



— Edição V4 - Ano 2024

— Corpo Editorial

Editor Chefe

Prof. Dr. Vicente de Lima Gongora

— Comitê Executivo

Profa. Esp. Adriana Giseli Leite Carvalho

Prof. Esp. Antônio Carlos Rodrigues

Profa. Dra. Camila Fogaça de Oliveira

Prof. Me. Fabio Rodrigo Milanez

Prof. Dr. Renato Kazuo Miyamoto

Prof. Dr. Rodolfo Alexandre Hildebrandt

Prof. Esp. Wesley Candido da Silva

Editora: Centro Universitário UniSenai Londrina

ISSN: 2358-5528

Direitos reservados

Centro Universitário UniSenai Londrina

Rua Belém, 844 - Londrina / PR (43) 3294-5100

Partes desta publicação poderão ser reproduzidas, sem a autorização prévia ou escrita deste Editor, desde que citada a fonte. Este periódico publica nomes individuais, comerciais, marcas registradas e produtos pertencentes a diversas companhias. O Editor utiliza-se destes nomes somente para fins editoriais e em benefício dos proprietários dos nomes e marcas, sem intenção de atingir seus direitos. Observa-se ainda que os dados contidos nos artigos são de responsabilidade dos próprios autores.

Editorial

**Edição TCCs - Inteligência Artificial e a
Indústria 4.0**

Prezados leitores e pesquisadores,
A Revista E-tec em seu volume 4 de 2024 tem como propósito apresentar pesquisas que representam o futuro da tecnologia aplicada à indústria. Nesta edição, reunimos artigos oriundos de Trabalhos de Conclusão de Curso (TCCs) que exploram sistemas inteligentes, com ênfase em redes neurais artificiais, aprendizado de máquina e suas aplicações no setor industrial. O avanço das tecnologias de inteligência artificial tem remodelado significativamente os processos produtivos, possibilitando otimizações, maior eficiência operacional e a tomada de decisões automatizadas com níveis de precisão antes inimagináveis. O impacto da Indústria 4.0 e o crescimento exponencial do Machine Learning trouxeram novas possibilidades de inovação, seja no monitoramento de equipamentos, previsão de falhas, otimização de processos produtivos ou controle de qualidade baseado em dados. Os trabalhos apresentados neste volume são exemplos da capacidade transformadora da pesquisa acadêmica quando aplicada às demandas reais da indústria. Esperamos que esta edição da Revista E-tec inspire novas pesquisas e contribua para o avanço do conhecimento na área de sistemas inteligentes aplicados à indústria. Boa leitura!

Atenciosamente,
Vicente Gongora [Editor-Chefe]

Feira de Profissões do UniSENAI Londrina Inspira Futuros Engenheiros e Técnicos



A Feira de Profissões do UniSENAI Londrina, realizada em 11 de novembro de 2024, reuniu cerca de 900 estudantes para conhecerem de perto as áreas de Engenharia Elétrica, Mecânica, Software e Automação Industrial. O evento proporcionou visitas a laboratórios da Unidade Dr. Celso Charuri, interação com equipamentos tecnológicos e demonstrações de projetos acadêmicos, além de orientações sobre o mercado de trabalho. A iniciativa reforçou o UniSENAI como referência em educação tecnológica, aproximando futuros profissionais das demandas da indústria.



— *Introdução*

Seja um aluno UniSenai PR

Excelência em engenharias:
Com uma visão voltada para o futuro da indústria, formamos profissionais capacitados a impulsionar o desenvolvimento e a gerar soluções inovadoras para o setor industrial.

Cursos ofertados:

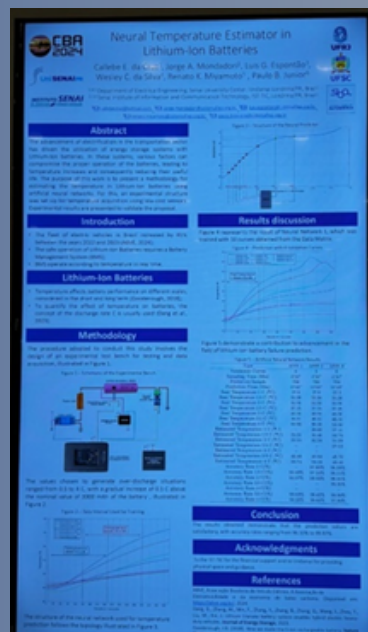
- Engenharia Mecânica
- Engenharia Elétrica
- Engenharia de Software
- Tecnologia em Automação Industrial



— Fique por dentro

UniSENAI Londrina participa do CBA 2024, o maior Congresso de Automática do Brasil

A participação da UniSENAI Londrina no XXV Congresso Brasileiro de Automática (CBA 2024), o maior evento do país na área, consolidou a instituição como referência em inovação e pesquisa aplicada à indústria. O professor Renato Kazuo Miyamoto representou a UniSENAI na apresentação do artigo "Neural Temperature Estimator in Lithium-Ion Batteries", fruto do Trabalho de Conclusão de Curso (TCC) do egresso Callebe E. da Cruz, desenvolvido em parceria com a empresa Voltipile e o Instituto Senai de Tecnologia (IST). O estudo utiliza redes neurais artificiais para estimar a temperatura de baterias de íons de lítio com sensores de baixo custo, trazendo contribuições significativas para a área de eletrificação de veículos.



Saiba Mais:



[HTTPS://CBA2024.VIDAESTUDANTIL.COM/](https://CBA2024.VIDAESTUDANTIL.COM/)

— GP de Inovação

Equipe do UniSENAI Londrina Conquista 3º Lugar no GP América Latina com Solução para Indústria de Alimentos

A equipe do UniSENAI Londrina conquistou o 3º lugar na categoria Alimentos no Grand Prix SENAI de Inovação América Latina 2024, uma das maiores competições de inovação da região. O projeto desenvolvido atendeu a uma demanda do Grupo Selmi, focando na otimização de processos produtivos para a indústria alimentícia. Durante o evento, os estudantes aplicaram metodologias de inovação aberta, desenvolveram um protótipo MVP e apresentaram sua solução para avaliadores e mentores da indústria. A premiação reforça o potencial inovador dos alunos e a importância da conexão entre educação e desafios reais do setor produtivo.



GP SENAI DE INOVAÇÃO
AMÉRICA LATINA

3

DESAFIO: ALIMENTOS | EMPRESA: GRUPO SELMI

	CATEGORIA	EQUIPE	SOLUÇÃO	ESTADO	ESCOLA(S)
3º LUGAR	INSPIRAÇÃO	NOT A NUMBER	NEEXO	SÃO PAULO	SENAI - JAÚ
	EVOLUÇÃO	UNIDOSENAI	PROJETO INTEGRAÇÃO 4.0	PARANÁ	UNISENAI - LONDRINA

— *Sumário*

Capítulo I

Aplicação de Redes Neurais Artificiais para a Gestão e Eficiência Energética em Sistemas Industriais e Comerciais Pg. 09

Capítulo II



Desenvolvimento de um Estimador de Velocidade Sensorless para Motor CC utilizando Redes Neurais Pg. 50

Capítulo III

Análise Comparativa entre Controladores PI e PI-Neural em Sistemas Térmicos Pg. 76

Capítulo IV

Sintonia Adaptativa de Controladores PID Utilizando Redes Neurais Pg. 109



Capítulo I – Aplicação de Redes Neurais Artificiais para a Gestão e Eficiência Energética em Sistemas Industriais e Comerciais

Bruno Pedroso de Toledo ¹

Layhon Roberto Rodrigues ²

Leonardo Yuji Ishizaki ³

RESUMO

Este trabalho investiga a gestão de energia e eficiência energética no Mercado Livre de Energia (MLE), com foco na aplicação de Redes Neurais Artificiais (RNA) para estimar o consumo energético (MWh) e otimizar a compra de energia, respeitando as normas vigentes. Especificamente, serão utilizadas Redes Perceptron Multicamadas (PMC) como aproximadoras de funções para prever padrões de consumo a partir de um banco de dados, permitindo projeções mais precisas. O estudo compara a abordagem baseada em RNA com um método tradicional de estimativa de demanda energética, visando demonstrar a capacidade das redes neurais de lidar com a volatilidade do Ambiente de Contratação Livre (ACL). O objetivo é consolidar um método eficiente para gerenciamento energético, minimizando custos operacionais e contribuindo para uma gestão mais sustentável e inteligente para empresas do Grupo Tarifário A.

Palavras-chave: Gestão de Energia, Eficiência Energética, Mercado Livre de Energia, Redes Neurais Artificiais, Perceptron Multicamadas.

Application of Artificial Neural Networks for Energy Management and Efficiency in Industrial and Commercial Systems

ABSTRACT

This study investigates energy management and energy efficiency in the Free Energy Market (MLE), focusing on the application of Artificial Neural Networks (ANNs) to estimate energy consumption (MWh) and optimize energy purchasing while complying with current regulations. Specifically, Multilayer Perceptron (MLP) Networks will be used as function approximators to predict consumption patterns based on a database, enabling more accurate projections. The study compares the ANN-based approach with a traditional energy demand estimation method, aiming to demonstrate the capability of neural networks to handle the volatility of the Free Contracting Environment (ACL). The goal is to establish an efficient energy management strategy, minimizing operational costs and contributing to a more sustainable and intelligent management for companies in the Group A Tariff category.

Keywords: Energy Management, Energy Efficiency, Free Energy Market, Artificial Neural Networks, Multilayer Perceptron.

¹ Engenheiro Eletricista. UniSenaiPR - Campus Londrina.

² Doutor em Engenharia Elétrica.

³ Mestre em Engenharia Elétrica.

1 INTRODUÇÃO

A crescente demanda pelo consumo de energia elétrica e a evolução da comercialização desse recurso vem ganhando atenção da indústria e pesquisadores, pois a dependência de energia elétrica se intensifica, impulsionada por uma diversidade de setores, dos mais diversos segmentos indústrias e residenciais. (HARRIS,2006).

O índice evolutivo de uma população segundo (KARDASHEV,1964) está diretamente relacionado a sua capacidade de aproveitar e controlar a energia disponível em seu ambiente. A capacidade de gerar e gerir este recurso, possui extrema relevância no âmbito comercial. Os apontamentos feitos pela Federação das Indústrias do Estado de Rio de Janeiro (FIRJAN, 2023) relatam que a energia elétrica é um insumo fundamental e estratégico sendo utilizado por 79% das empresas e chegando a representar mais de 40% de seus custos de produção.

Um relatório publicado pela Agência Internacional de Energia em (AIE, 2022), aponta que demanda global por eletricidade aumentou em 6% em 2021. Este aumento se sucederá ainda maior quando ambientalizamos o Mercado Livre de Energia (MLE), os quais podem realizar a compra de seu volume energético não só da companhia local concessionária, mas também de diversas outras comercializadoras, este assunto será abordado em mais detalhes na seção 1.3. Desde janeiro de 2023 através da Portaria nº465/2019 consumidores com consumo acima de 500kW já podem fazer parte do Ambiente de Contratação Livre (ACL), este fato que já possui grande impacto tende a aumentar ainda mais, uma vez que a Portaria nº50 que entrará em vigor a partir de 2024, permitirá que consumidores atendidos em Média Tensão (13.8kV) possam migrar ao ACL. Tal marco contribui verticalmente para o avanço da matriz energética e estratégias eficientes de gestão deste recurso, tanto para o meio social sustentável, quanto a estratégias de mercado e competitividade entre as empresas. (ENGIE,2020).

No contexto discutido anteriormente, de ambiente de contratação livre, de demanda energética, este trabalho visa implementar um estimador de demanda para otimizar a contratação de energia elétrica no mercado livre. Para isso, se implementa uma Rede Neural Artificial como uma aproximadora de funções, e esta, será treinada

de modo a interpretar o padrão de consumo sazonal para diversas áreas e estimar o volume energético demandado.

A seguir este trabalho está organizado da seguinte forma: a Seção 2 descreve a fundamentação teórica onde serão abordados aspectos relevantes da literatura que embasam este trabalho, como fundamentos de "Geração, Transmissão, Distribuição e Comercialização de Energia Elétrica" e fundamentos de Redes Neurais Artificiais (RNA), já na seção 3 será abordada a metodologia utilizada para implementação da RNA com foco em atingir os objetivos gerais e específicos citados na subseção 1.1 e 1.1.1. Na seção 4 e 4.1 serão apresentadas as conclusões e discussões de resultados, as métricas extraídas da metodologia implementada serão analisadas a partir do viés financeiro, por fim na seção 5 serão feitas considerações finais deste trabalho.

2 FUNDAMENTAÇÃO TEÓRICA

Nesta seção serão discutidos aspectos relevantes da literatura que embasam este trabalho, na subseção 2.1 serão abordados fundamentos de "Geração, Transmissão, Distribuição e Comercialização de Energia Elétrica" com intuito de ambientar o cenário que motiva este estudo e, como este cenário possui vastas possibilidades de atuação dada sua complexidade e representatividade econômica global. Na subseção 2.2 será apresentado e contextualizado o ambiente de contratação regulada ACR. Na subseção 2.3 e 2.3.1 conduzirá uma análise sobre a dinâmica operacional do Ambiente de Contratação Livre (ACL). Serão abordados conceitos cruciais, tais como a atuação de órgãos reguladores e a legislação que dita as regras neste cenário. A compreensão desses elementos é fundamental para contextualizar as estratégias de implementação discutidas neste trabalho. Já na subseção 2.4 e 2.4.1 serão apresentadas funcionalismo das Redes Neurais Artificiais (RNA) de maneira a introduzir como estas ferramentas serão utilizados no desenvolvimento destes estudos. Nas subseções 2.4.1.1 até 2.4.1.3 são apresentados e discutidos os métodos de treinos que serão utilizados e comparados, nesta serão abordadas e discutidas as equações que modelam os treinos e como cada qual poderá contribuir para o desenvolvimento deste trabalho.

2.1 GERAÇÃO TRANSMISSÃO DISTRIBUIÇÃO E COMERCIALIZAÇÃO DE ENERGIA ELÉTRICA.

A matriz energética possui diversos órgãos reguladores para sancionar leis e traçar as diretrizes no quesito comercialização e distribuição de energia, isto só foi possível graças ao inventor austríaco Nikola Tesla cientista o qual difundiu os conceitos da 'Alternate Currente' (AC), possibilitando assim os meios de transmissão de energia as quais utilizamos atualmente. (NIKOLA TESLA,2023).

Com o crescimento da matriz energética surgiram os órgãos regulatórios, como o “Conselho Nacional de Política Energética” (CNPE), “Ministério de Minas e Energia” (MME) “Agência Nacional de Energia Elétrica” (ANEEL), “Empresa de Pesquisa Energética” (EPE), “Comitê de Monitoramento do Setor Elétrico” (CMSE), Câmara de Comercialização de Energia Elétrica “(CCEE) “Operador Nacional do Sistema Elétrico” (ONS). Através da Figura 1 pode-se observar a configuração hierárquica destes órgãos.

Figura 1. Órgãos Regulamentadores Setor Elétrico Nacional.



Fonte:Falcão,2020.

Com o avanço do uso pelo sistema elétrico, foi-se criada uma segmentação em dois nichos, clientes do Grupo B (Baixa Tensão) descritos por unidades consumidoras que possuem demanda contratada abaixo de 75kW de representada por casas e pequenos comércios, para clientes com demanda contratada acima de 75kW são consideradas pertencentes ao Grupo A (Alta Tensão), isto é importante pois reflete leis e modelagem de tarifação diferentes para ambos que serão mais bem detalhadas nas subseções 1.3 e 1.4.

2.2 AMBIENTE DE CONTRATAÇÃO REGULADA (ACR).

O ambiente de contratação regulada (ACR) ou mercado cativo de energia elétrica é um modelo tradicional de comercialização no setor elétrico, em que os consumidores (Grupo B – Baixa Tensão) são atendidos por concessionárias de distribuição designadas, estabelecendo uma relação de exclusividade. É bastante relevante destacar neste modelo de comercialização de energia elétrica, os quais os consumidores não têm liberdade para escolher seu fornecedor de energia elétrica, sendo obrigados a adquiri-la da concessionária designada para a região em que estão localizados (ANEEL,2022).

As concessionárias de energia são responsáveis por comercializar e distribuir energia elétrica aos consumidores finais, gerenciar a infraestrutura de distribuição e garantir a qualidade e confiabilidade do serviço (ANEEL,2022). As concessionárias atendem a todos consumidores residências, que fazem parte da topologia ACR para a contratação de energia elétrica, toda as diretrizes regulatórias são regidas pela Agência Nacional de Energia Elétrica (ANEEL), a qual estabelece as tarifas e regulamentações a serem seguidas pelas concessionárias. (“CARTILHA MERCADO LIVRE DE ENERGIA ELÉTRICA”, 2019)

No mercado cativo, as tarifas de energia elétrica são definidas com base em critérios estabelecidos pela ANEEL, que leva em consideração os custos de geração, de transmissão, de distribuição e de encargos setoriais. Os consumidores cativos são faturados de acordo com estes custos, os quais variam de acordo com o perfil de consumo e a categoria de cliente.

2.3 COMERCIALIZAÇÃO ENERGIA ELÉTRICA E SURGIMENTO DO AMBIENTE DE CONTRATAÇÃO LIVRE (ACL).

O sistema elétrico possui grande impacto no mercado econômico mundial, com o aumento e expansão das fontes geradoras de energias renováveis como Usinas Fotovoltaicas (UFV), Usinadas Eólicas (UE), Biomassa e Pequenas Centrais Hidrelétricas (PCH's) surgiu um nicho de mercado muito atrativo, onde grandes empresas com enfoque comercial, passaram ter a possibilidade de gerar sua própria energia e injetá-las no sistema elétrico de distribuição das concessionárias , isto

expandiu o método de comercialização pois com isto não apenas a concessionária de energia é capaz de gerar e distribuir mas sim diversas empresas que investem neste mercado. Com isto segundo (SILVA,2020), a possibilidade de compra com diversos fornecedores permitiu cotações mais baratas ao valor unitário do MWh comercializado, sendo assim em 2019 houve uma economia de R\$ 200 bilhões de reais aos consumidores que operaram no mercado livre de totalizando 34% de redução em seus custos com energia elétrica.

Este modelo de comercialização passou a ser “Livre”, denominando-se assim ACL (Ambiente de Contratação Livre), porém com o surgimento deste cenário houve necessidade de criação de leis que sustentação as diretrizes de como este ambiente se sucederá, a Lei 9074 de 1995 estabelece as normativas bem como os meios para comercialização do volume energético no ACL. (MACHADO,2022).

Este ambiente de contratação segundo (SILVA,2022) expandiu o mercado econômico mundial e trouxe maior flexibilidade na negociação e aquisição de energia elétrica. O modelo ACL surge como uma proposta de superar o modelo tradicional do setor elétrico, que é caracterizado por um modelo verticalmente integrado, em que as concessionárias de distribuição eram responsáveis tanto pela geração, transmissão, distribuição e pela comercialização da energia. No entanto, este o modelo ACR apresenta limitações em termos de competitividade, de transparência e de possibilidade da escolha entre qual fornecedor realizar a compra de sua energia.

Com o advento do Ambiente de Contratação Livre (ACL), houve a separação das atividades de geração e comercialização de energia elétrica. Contudo, as fases de transmissão e distribuição permanecem sob a responsabilidade da concessionária, incumbida de zelar pela manutenção da infraestrutura. Em decorrência dessa estruturação, são pagos a companhia de energia elétrica apenas a "Tarifa pelo Uso do Sistema de Distribuição (TUSD)" após celebração do "Contrato pelo Uso do Sistema de Distribuição (CUSD)", tal topologia de distribuição é representada pelo Sistema Interligado Internacional (SIN). (“CARTILHA MERCADO LIVRE DE ENERGIA ELÉTRICA”, 2019)

O Mercado Livre de Energia, viabilizado pela Câmara de Comercialização de Energia Elétrica (CCEE), possibilita que consumidores e geradores negociem contratos de energia de forma livre, estabelecendo preços e condições de acordo com

suas necessidades e interesses. De acordo com (CASADEI,2023) a inserção nesse ambiente propicia a redução significativa, podendo alcançar até 20%, nos custos finais com energia elétrica para consumidores atendidos em média tensão. Essa flexibilidade e potencial economia destacam os benefícios e as oportunidades oferecidas pelo Mercado Livre de Energia aos participantes.

Com o surgimento do ambiente de contratação livre abriu espaço para a entrada de novos agentes comercializadores fomentando a competição no mercado financeiro. Além disto, o mercado livre de energia impulsionou o desenvolvimento de novas tecnologias e práticas de gestão que norteia o objetivo deste trabalho, “Em 1º de janeiro de 2024, todos os consumidores de energia elétrica atendidos em alta tensão segundo a Portaria nº 50 estarão aptos a participar do mercado livre de energia elétrica. Potencialmente, 106 mil consumidores a mais passam a se beneficiar deste direito” (CASADEI, 2023).


2.3.1 FUNCIONALISMO AMBIENTE CONTRATAÇÃO LIVRE.

No Ambiente de Contratação Livre (ACL), os consumidores têm a capacidade de estabelecer contratos para a aquisição de um determinado volume energético, medido em Mega Watt Médio (MWh) diretamente com os geradores ou comercializadoras de energia. Esses contratos podem ser realizados em diferentes configurações, conhecidas como Mercado de Curto Prazo (MCP), Mercado de Médio Prazo (MMP) e Mercado de Longo Prazo (MLP) (CCEE, 2020). A formalização desses contratos ocorre por meio do registro na Câmara de Comercialização de Energia Elétrica (CCEE), uma entidade encarregada de monitorar e registrar as operações realizadas no mercado livre. Além disso, a CCEE é responsável por conduzir a liquidação das diferenças, conhecida como "Preço de Liquidação das Diferenças" (PLD). Qualquer discrepância no volume energético ao final do mês é automaticamente negociada com base no valor do PLD (Figura 2), a menos que o consumidor opte por uma venda consciente a uma comercializadora.

Nesse contexto, a gestão de excedentes ou a aquisição de volume energético adicional pode representar um desafio significativo para as empresas, podendo resultar em prejuízos substanciais. Com base nessa perspectiva, a utilização de

Redes Neurais Artificiais (RNA) pode proporcionar estimativas mais precisas, oferecendo suporte às operações de compra de energia.

Figura 2. Variação PLD 2001 a 2023.



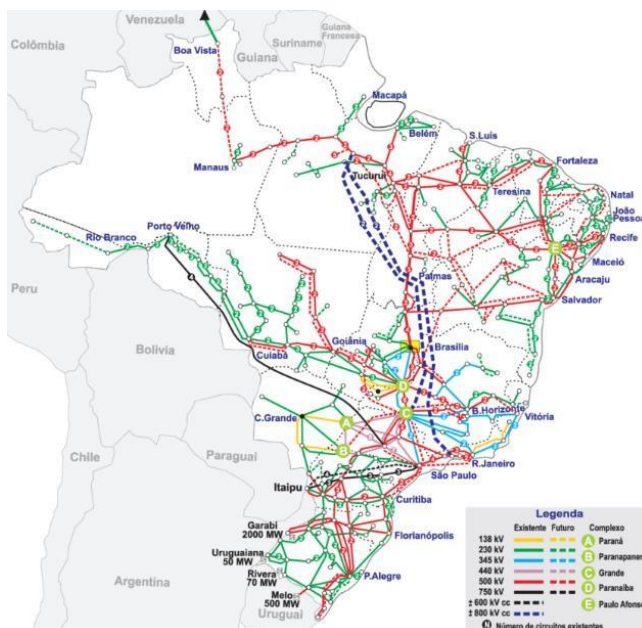
Fonte: Electra,2023.

Conforme destacado pela ("Cartilha Mercado Livre de Energia Elétrica", 2019), o registro na CCEE é fundamental para garantir a segurança e a transparência nas transações, conferindo aos consumidores o direito de receber o volume energético contratado.

A energia elétrica é distribuída através do Sistema Interligado Nacional (SIN) representado na Figura 3. A gestão do sistema de distribuição é de responsabilidade da concessionária da região. Ao firmar o contrato de compra do volume energético com a Câmara de Comercialização de Energia Elétrica (CCEE), torna-se imperativo o cumprimento desse contrato, garantindo a satisfação das demandas de distribuição necessárias.

O uso desse sistema de distribuição é refletido na fatura como a Tarifa de Uso do Sistema de Distribuição (TUSD), sendo o pagamento direcionado à distribuidora responsável. Esse processo estabelece uma conexão essencial entre o cumprimento dos contratos e a efetiva utilização do sistema de distribuição, reforçando a interdependência entre esses elementos no contexto do mercado elétrico (ANEEL,2022).

Figura 3. Sistema Interligado Nacional (SIN).



Fonte: Cartilha Mercado Livre de Energia Elétrica" (2019).

Na Figura 4, a ferramenta de análise aplicada ao método SWOT foi empregada para delinear e compreender o ambiente de contratação livre. Destaca-se que, nesse contexto, a gestão de riscos é identificada como uma fraqueza, refletindo a volatilidade dos preços e a necessidade crítica de gerenciamento de riscos. Essa vulnerabilidade é exemplificada pela possibilidade de prejuízos decorrentes da venda de um volume energético a valores do Preço de Liquidação das Diferenças (PLD), resultante de decisões inadequadas no momento da contratação do volume energético (MWh).

Figura 4. Análise SWOT ACL.


SWOT - Ambiente Contratação Livre ACL	
<p>Forças</p> <p>FLEXIBILIDADE CONTRATUAL</p> <p>COMPETIÇÃO E PREÇOS</p> <p>DIVERSIFICAÇÃO DE MATRIZ DE GERAÇÃO</p> <p>POTENCIAL ECONOMIA</p>	<p>Fraquezas</p> <p>COMPLEXIDADE CONTRATUAL</p> <p>GESTÃO DE RISCOS</p> <p>REQUISITOS TÉCNICOS</p> <p>DEPENDÊNCIA DE FATORES EXTERNOS</p>
<p>Oportunidades</p> <p>EXPANSÃO DO MERCADO</p> <p>DESENVOLVIMENTO DE ENERGIAS RENOVÁVEIS</p> <p>INCENTIVOS GOVERNAMENTAIS</p> <p>TECNOLOGIAS EMERGENTES</p>	<p>Ameaças</p> <p>VARIAÇÕES CLIMÁTICAS</p> <p>REGULAMENTAÇÃO</p> <p>VOLATILIDADE DE PREÇOS</p> <p>CONCORRÊNCIA COM FONTES CONVENCIONAIS</p>

Fonte: Autoria Própria, 2023.

2.4 REDES NEURAIS ARTIFICIAIS

As redes neurais são modelos computacionais inspirados no funcionamento do cérebro humano que possui capacidade de aprendizado a partir de dados. Elas são compostas por unidades de processamento interconectadas, chamadas de neurônios artificiais (Figura 5), que operam em paralelo para realizar cálculos complexos, segundo (Cajál,1911) os neurônios humanos processam informações na base aproximada de 10⁻³s, já eventos ocorridos em portas lógicas de silício tem seu processamento aproximado de 10⁻⁹s. Apesar dos neurônios humanos terem seu processamento de informação mais lento em relação as referidas portas lógicas, o cérebro humano compensa com expressivas quantidades de neurônios interconectados entre si. (HAYKIN,2001). Essa capacidade de processamento paralelo e aprendizado permite que as redes neurais identifiquem padrões e relações em conjuntos de dados, tornando-as uma ferramenta poderosa para a análise, classificação e previsão (“Redes Neurais Artificiais; USP”,2016)

Figura 5. Constituintes da célula neuronal – Esquema




Fonte: Redes Neúais Aítificiais; USP (2016).

O processo de aprendizagem de uma rede neural é denominado algoritmo de aprendizagem. Em 1949, Donald Hebb fez grandes contribuições para área, ao assimilar que o processo de aprendizagem neural humano se dava através da relação entre neurônios mesmo que estes estivessem distantes entre si (“ORIGEM E CONCEITO NEUROPEDAGOGIA, [s.d.] este percebeu que se dois neurônios são ativos a relação sináptica entre eles é reforçada, esta relação sináptica é semelhante aos filtros adaptivos lineares (Haykin, 2001) desta analogia possibilitou-se grandes

avanços na área das redes neurais uma vez que esta otimiza o processo de aprendizado da rede.

A rede neural artificial é disposta de configuração simples, sua complexidade se dá conforme aumenta-se o tamanho da rede com isto aumenta-se também o processamento desta (“Redes Neurais Artificiais; USP”,2016). McCullock e Pitts em 1943 resumiram o funcionamento de uma rede neural artificial esta ficou disposta conforme apresentada, tal como ilustrado na Figura 6.

Figura 6. Esquema de unidade McCullock – Pitts.




Fonte: Redes Neurais Artificiais; USP, 2016.].

Em síntese, a topologia da Figura 6 é operacionalizada por meio de operações matemáticas, onde um vetor de entradas $x = [x_1, x_2, \dots, x_n]$ é multiplicado por um vetor peso $w = [w_1, w_2, \dots, w_n]$, então é realizada a operação $\sum^n x_i \cdot w_i$, que é um somatório do produto escalar do i -ésimo elemento do vetor de pesos e da i -ésima entrada, que na sequência passa por uma função de ativação que possa representar a saída y de forma adequada.

2.4.1 REDES NEURAS PERCEPTRON MULTICAMADAS

A Rede Perceptron de Múltiplas Camadas (PMC) representa um marco fundamental no campo de aprendizado de máquina e inteligência artificial. Introduzida como uma extensão do Perceptron simples, a PMC supera as limitações deste último, possibilitando a abordagem de tarefas mais complexas e não lineares. Composta por camadas de neurônios interconectados conforme representado pela Figura 7, a PMC destaca-se por sua capacidade intrínseca de aprender e generalizar padrões a partir de conjuntos de dados (Redes Neurais Artificiais; USP,2016).


Figura 7. Peícenton Multicamadas - PMC



Fonte: SILVA; SPATI; FLAUZINO (2010)

Uma abordagem de implementação de uma Rede Neural Artificial Perceptron Multicamadas (RNA – PMC) envolve a aplicação da regra delta. Esse método segundo (SIMON,2000), permite a implementação de um treinamento supervisionado do tipo 'feedforward', no qual se avalia o valor do 'Mean Square Error' (MSE), uma métrica que expressa a discrepância entre a saída prevista pela rede e o valor desejado. A partir do cálculo do MSE, obtém-se um valor delta, que, por sua vez, é utilizado no processo de retro propagação ('backward'). Durante essa etapa, o vetor de pesos é atualizado de maneira a minimizar o MSE, conforme ilustrado nas Figuras 8 e 9. Esse procedimento visa otimizar o desempenho da RNA PMC, ajustando seus pesos para se aproximar do resultado desejado. (SILVA,2010).

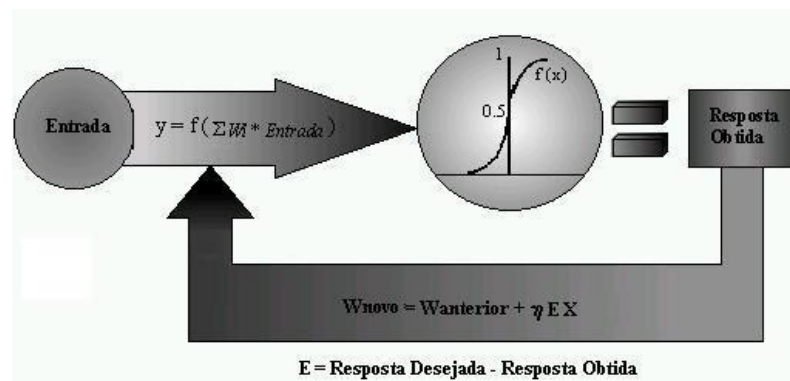
Figura 8. Regra delta.



Fonte: Redes Neurais Artificiais; USP , 2016].

A Figura 9, representa a modelagem esquemática de treino de uma RNA PMC. Nesta figura são inseridos dados de entrada previamente normalizados e armazenado na variável E (entrada de dados) e y representa a resposta de saída da RNA, ao passar pela função de ativação é comparada com o desejado e o valor de Δ atualiza o vetor de pesos da rede conduzindo-a aproximação do valor desejado.

Figura 9. Esquema de treinamento do Perceptron.



Fonte: Redes Neurais Artificiais; USP, 2016.

2.4.1.1 MÉTODO LEVENBERG – MAQUARDT

A metodologia de Levenberg-Marquardt (LMA) é considerada a mais rápida dos algoritmos de treinamento retro propagação de erro, segundo (GONCALVES et. al., 2010). Embora o método e LMA exija mais memória computacional do que outros algoritmos, este método possui características vantajosas. A metodologia de Levenberg-Marquardt se destaca por sua capacidade de convergir eficazmente em sistemas não lineares, segundo (ADERALDO; ADEMIR; RIBEIRO, [s.d.]). A robustez e eficiência desse método tornam-no uma excelente ferramenta para implementação da RNA proposta.

Em sua modelagem matemática, a introdução do parâmetro λ_k , conforme descrito na Equação 1.

$$(J^T(X_k)J(X_k) + \lambda_k I) d_k = (-J^T(X_k)R(X_k)) \quad (1)$$

permite a adaptação da direção e do tamanho do passo durante a otimização, garantindo que a rede neural possa explorar eficientemente o espaço de busca em diferentes cenários, inclusive em problemas não lineares.

A modelagem da matemática da Equação 1 , é descrita através das seguintes variáveis :

$JT(Xk)$: É a transposta da matriz Jacobiana no ponto Xk . A matriz Jacobiana é uma matriz que contém as derivadas parciais de um sistema de equações em relação às variáveis independentes. A transposta é obtida trocando as linhas pelas colunas.

$J(Xk)$: Representa a matriz Jacobiana no ponto Xk

λk parâmetro de Levenberg Marquadt (LMA) , Ele controla a quantidade de ajuste que é feito em cada iteração. Quando λk é grande, o método age mais como o método do Gradiente Descendente. Se λk é pequeno, o método se aproxima do método de Gauss-Newton.

I é a matriz identidade da equação.

$d k$,o vetor de incremento que é adicionado à estimativa atual Xk . Este vetor representa a direção na qual estamos ajustando os parâmetros.

$R(Xk)$ O vetor de resíduos no ponto Xk . Os resíduos são as diferenças entre as observações reais e as estimativas do modelo.

Tais variáveis que modelagem o algoritmo de treino de Levenberg Marquadt, faz deste método uma proposta robusta e eficiente por ser adaptável a diversos sistemas sejam eles lineares ou não.

2.4.1.2 GRADIENTE DESCENDENTE.

A metodologia do Gradiente Descendente é um dos algoritmos mais utilizada na literatura, por se tratar de um algoritmo primitivo, possuindo uma vasta aplicabilidade em problemas de 'machine learning' (UFPR,2019).

O método do gradiente descendente é uma técnica iterativa para otimizar funções. Ele ajusta os parâmetros da função de maneira a minimizar gradativamente o valor da função objetivo. A cada iteração, o método calcula o gradiente da função no ponto atual e dá um passo na direção oposta para encontrar um mínimo local. A regularização com um termo de penalidade auxilia na estabilidade do processo. Isso é feito até que a convergência seja alcançada, proporcionando uma solução eficiente para problemas de otimização (UFPR, [s.d]). A formulação matemática do método do gradiente descendente é descrita através da Equação 2.


$$\beta^{(k+1)} = \arg \min_{\beta} J(\beta^{(k)}) + \nabla J(\beta^{(k)}) (\beta - \beta^{(k)}) + \frac{1}{2a} \|\beta - \beta^{(k)}\|^2. \quad (2)$$

Processo de aproximação se dá ao substituir o termo $12a$ por $\nabla^2 J(\beta^{(k)})$ ao derivamos em função de β e igualando a equação a zero, obtém-se temos a Equação 3 que convergirá necessariamente a um mínimo local devido a primeira derivada.

$$\beta^{(k+1)} = \beta^{(k)} - a \nabla J(\beta^{(k)}). \quad (3)$$

Através desta modelagem matemática é possível realizar uma aproximação a a partir de um ponto inicial P_0 representado pela Figura 10.

Figura 10. Modelo Aproximador – Gradiente Descendente.



Fonte: UFPR,[s.d] - Laboratório Estatística.

2.4.1.3 BFGS Broyden–Fletcher–Goldfarb Shanno Quasi – Newton

O método Broyden-Fletcher-Goldfarb-Shanno (BFGS) é um algoritmo de otimização utilizado para encontrar o mínimo (ou máximo) de uma função diferenciável. Ele pertence à categoria de métodos Quasi-Newton, que são métodos iterativos de otimização que não exigem o cálculo direto da matriz Hessiana (segundas derivadas parciais) da função (MUKHERJEE; ROUTROY, 2012).

Este método é fundamentado pela Equação 4, onde $W(t + 1)$ representa os parâmetros atualizados após a iteração e $W(t)$ os parâmetros atuais antes da iteração, αt delimita o tamanho do passo de busca da RNA na direção desejada. Já o $\nabla J(W(t))$ é o radiante da função objetivo $J(W)$ em relação aos parâmetros do ponto $W(t)$ indicando a direção na qual a função mais cresce, o último parâmetro da equação explica menção feita por (MUKHERJEE; ROUTROY, 2012), onde $\nabla^2 J(W(t))^{-1}$

é a inversa da matriz Hessiana que é uma aproximação da segunda derivada de $J(W)$. Esta matriz é usada para ajustar a direção do passo e controlar a curvatura da função.

$$W(t + 1) = W(t) - a_t \cdot [\nabla^2 J(W(t))]^{-1} \cdot \nabla J(W(t)) \quad (4)$$

A equação geralmente é derivada usando técnicas de otimização e cálculo matricial. Em resumo, ela indica que, para encontrar os parâmetros otimizados $W(t + 1)$, você ajusta os parâmetros atuais $W(t)$ na direção oposta ao gradiente da função, ponderado pela inversa da matriz Hessiana.

3 METODOLOGIA

Nesta seção são abordados os conceitos e procedimentos necessários para a implementação da Perceptron Multicamadas (PMC) para estimativa de demanda energética. Esta abordagem tem como foco estimativa de demanda por meio da análise do perfil de consumo de energia, que se baseia nas variáveis de entrada, que são as áreas construídas de cada estabelecimento e meses, bem como a variável de saída que é a demanda energética de cada estabelecimento. A área construída está diretamente relacionada com a demanda energética e o mês está relacionado com sazonalidade, que também reflete na demanda energética.

As variáveis de entrada possuem valores absolutos e grandezas diferentes, por exemplo, a área e sua unidade em m², o mês em unidade unidimensional, e consumo energético e a sua unidade kWh. Estas diferentes intensidades e grandezas das variáveis precisam ser normalizadas em escalas similares e unidades equivalentes, para evitarem o domínio da intensidade de maior valor. Por esta razão, adota-se a normalização por unidade (PU - 'per unit'), para uma garantia de escalas similares entre as diferentes variáveis de entrada e de saída. As bases para cada uma das variáveis são pré-determinadas pelos valores máximos destas, de cada uma das unidades (BICHELS,2018).

A análise de relevância das variáveis de entrada para a estimativa da demanda energética é avaliada por meio da correlação de Pearson. A correlação de Pearson é um método estático, consolidado na literatura (LIRA,2004), que permite estimar o quão correlacionadas estão as variáveis de entrada e de saída. A máxima correlação

diretamente proporcional entre duas variáveis é encontrada quando a correlação de Pearson entre uma das variáveis de entrada e a saída é igual 1, enquanto a máxima correlação inversamente proporcional entre duas variáveis é encontrada quando a correlação de Pearson entre uma das variáveis de entrada e a saída é igual a - 1, e não há correlação entre duas variáveis quando a correlação de Pearson entre duas variáveis é zero.

A rede PMC é avaliada em diferentes topologias, que são configuradas com diferentes métodos de otimização, dentre eles, o método de otimização Levenberg-Marquardt, Gradiente Descendente, Gradiente Descendente e Broyden-Fletcher-Goldfarb Shanno Quasi – Newton (BFGS), e diferente quantidade de neurônios. Em cada topologia se analisa o erro quadrático médio, para então determinar aquela que retorna a melhor estimativa de demanda energética.

A seguir, as etapas metodológicas desta seção são discutidas em detalhes: a Subseção 3.1., discute sobre os dados de entrada e saída e a suas respectivas normalizações em PU; na subseção 3.2, trata sobre análise de relevância de variáveis por meio da correlação de Pearson; e por fim, a subseção 3.3, discute sobre as topologias consideradas para a rede neural PMC.

3.1 DADOS DE ENTRADA E SAÍDA


Os dados de entrada e saída desempenham papel importante na rede neural artificial PMC para a estimativa da demanda energética. As duas variáveis de entrada assumidas, a área (m^2) e o mês, se relacionam com a carga energética consumida de cada um dos estabelecimentos e a sazonalidades, respectivamente.

A área possui uma relação direta com a demanda energética de cada um dos estabelecimentos, que se dá principalmente pela carga de iluminação, de climatização, de refrigeração, dos computadores, dos fornos industriais, das estufas, dentre outras. Esta conexão entre os dados não apenas sustenta academicamente este trabalho, mas também constitui a base essencial para uma compreensão aprofundada das dinâmicas energéticas inerentes a cada setor.

Já o mês em particular, ao considerar o impacto sazonal, torna-se evidente que a demanda energética varia ao longo do ano. O mês específico pode desempenhar um papel crucial nessa dinâmica, influenciando diretamente a intensidade do consumo

em diferentes setores. Por exemplo, meses mais quentes podem aumentar a necessidade de climatização e refrigeração, enquanto períodos de demanda sazonal específica, como festas de final de ano, podem impactar o consumo de energia em setores relacionados a fornos industriais e iluminação decorativa.

Figura 11. Estrutura RNN PMC – Dados Entada e Saída.



Fonte: Autoria Própria (2023).

Dados de saída caracterizam os volumes de energia consumidos no período de 2021 à 2023 e estão dispostos de 462 dados para treinamento e validação da RNA.

3.1.1 TRATAMENTO DE DADOS

Dada a diversidade de dados, se torna essencial o tratamento de todas a informações manipuladas na rede neural. Esse processo assume dois tópicos principais, a elaboração da estrutura na qual os dados serão inseridos e a normalização deste para evitar propagação de erro, que será detalhada na Seção

3.1.2. Essa etapa desempenha um papel crucial no desempenho da Rede Neural Artificial (RNA), pois a falta de validação nessa fase comprometeria o desenvolvimento da rede.

Os dados de entrada e de saída utilizados neste trabalho foram estruturados de maneira linear, em que cada coluna é representa por uma entrada ou saída da rede neural, assim como a quantidade de linhas representa a quantidade de amostras, se configurando como assim uma matriz de dados. Tal organização proporciona uma disposição eficiente para a entrada na RNA, contribuindo para a eficácia do treinamento e da posterior análise dos resultados de estimativa de demanda energética.

3.1.2 NORMALIZAÇÃO DE DADOS

Para que a rede seja eficiente em seu processo de aprendizado (MATOS, 2023) refere-se a importância da normalização dos dados. Este procedimento, é essencial para garantir o máximo desempenho da RNA, pois evita que variáveis com diferentes escalas dominem o processo de treinamento, o que poderia impactar negativamente o desempenho da rede.

A normalização dos dados foi realizada por meio do método PU ("Per Unity"), o qual representa um valor percentual do maior valor da matriz. (BICHELS, 2018) Essa abordagem permite que os valores sejam dispostos em uma escala entre 0 e 1 para as variáveis de Volume Energético, Mês e Área Construída.

Realizar a normalização dos dados é um procedimento fundamental que tem como objetivo reescalar as variáveis de entrada, garantindo que todas estejam no mesmo 'range' de valores. A não normalização dos dados em escalas equivalentes pode acarretar em problemas como convergência lenta, estagnação da otimização ou falhas no aprendizado. Assim, a normalização dos dados se configura como uma etapa crítica para o sucesso do projeto.(MATOS,2023).

3.1.3 CORRELAÇÃO DE PEARSON

Para validação dos dados foi utilizado método de Pearson para análise de interação entre estes dados . A matriz de Pearson é uma ferramenta estatística extremamente relevante que nos permite avaliar as relações lineares entre variáveis, fornecendo "insights" valiosos sobre a conexão dessas variáveis. Neste estudo, estamos trabalhando com três variáveis fundamentais: mês, área e consumo (MWh).

De acordo com (Cohen,1988), podemos categorizar as relações entre os dados em três níveis com base em intervalos estabelecidos Tabela 1:

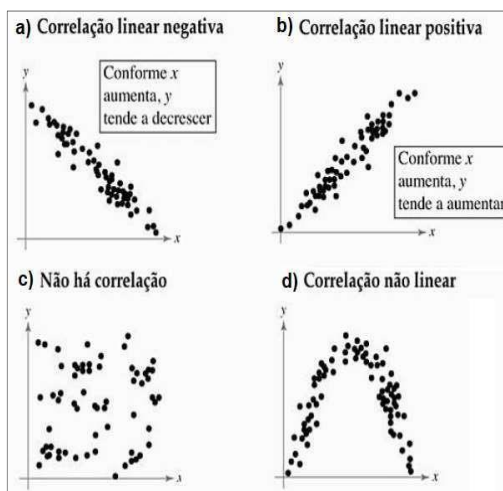
Tabela 1 – Correlação de Pearson

0,10 a 0,29	Baixa Correlação
0,30 a 0,49	Média Correlação
0,50 a 1,00	Alta Correlação

Fonte: Autoria Própria

Na Tabela 1, a relação entre os dados é definida por Pearson em uma escala que varia de -1 a 1. Valores positivos indicam uma correlação direta e valores negativos sugerem uma correlação inversa.

Figura 12. Exemplos de Associação linear



Fonte : LARSON, 2010, Pg. 395

A equação (5) representa a correlação de Pearson e mede a variação compartilhada entre duas variáveis.

$$r = \frac{1}{n-1} \sum \frac{x_i - \bar{x}}{\sigma_x} * \frac{y_i - \bar{y}}{\sigma_y} \quad (5)$$

Com o auxílio de ferramentas de análise estatística de dados, se utilizou o software “Jamovi” com o objetivo de aplicar a metodologia Pearson. Isto permitiu-nos realizar uma análise meticulosa da matriz de dados com a qual trabalhamos, com o objetivo de validar a força da interação entre os dados. Conforme ilustrado na Tabela 2, observamos que a matriz “Consumo” contendo 462 dados de consumo (MWh) e a matriz “Área” (m²), também com 462 dados, são classificadas como “Alta Correlação” segundo a Tabela 1, e as variáveis “Consumo” e “Mês” são classificadas com baixa correlação , o fato de possuir uma correlação viabiliza a implementação da

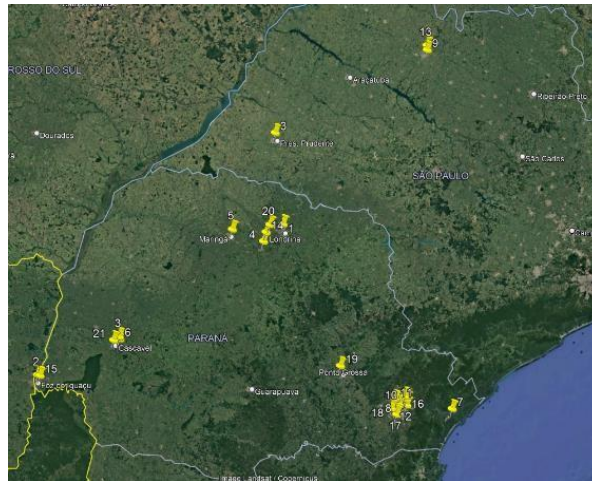
Tabela 2. Correlação de Pearson Dados Entrada.

Correlação de Pearson	
Consumo	
Área	0.741
Mês	0.182

Fonte: Autoria Própria, 2023.

A Figura 13 representa pontos físicos a qual estão situados estabelecimentos cujos dados farão parte do treinamento da rede neural artificial

Figura 13. Visão Geral Satélite

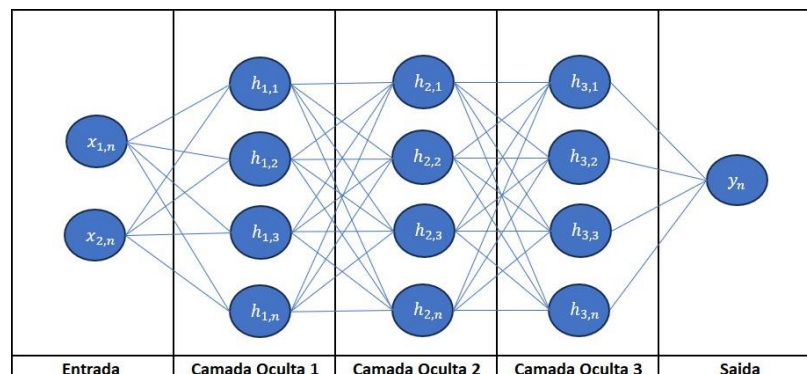


Fonte: Autoria Própria,2023.

3.3 PERCENTRON MULTICAMADAS

As redes neurais artificiais Perceptron de Múltiplas Camadas se distinguem pela inclusão de, no mínimo, uma camada intermediária composta por ‘ n ’ neurônios representada pela Figura 14. (KAZUO,2023). Foram adotadas algumas topologias de treino para a RNA PMC com objetivo de trazer métricas de comparação da resposta da rede. Tais métricas serão discutidas na seção 3.3.1.1, os métodos de “Levenberg - Marquardt”, “Gradient Descent” e “BFGS Quasi-Newton” respectivamente serão discutidos nas subseções 3.3.1.2 a 3.3.1.3.

Figura 14. Perceptron Multicamadas - PMC.



Fonte: Autoria Própria,2023.

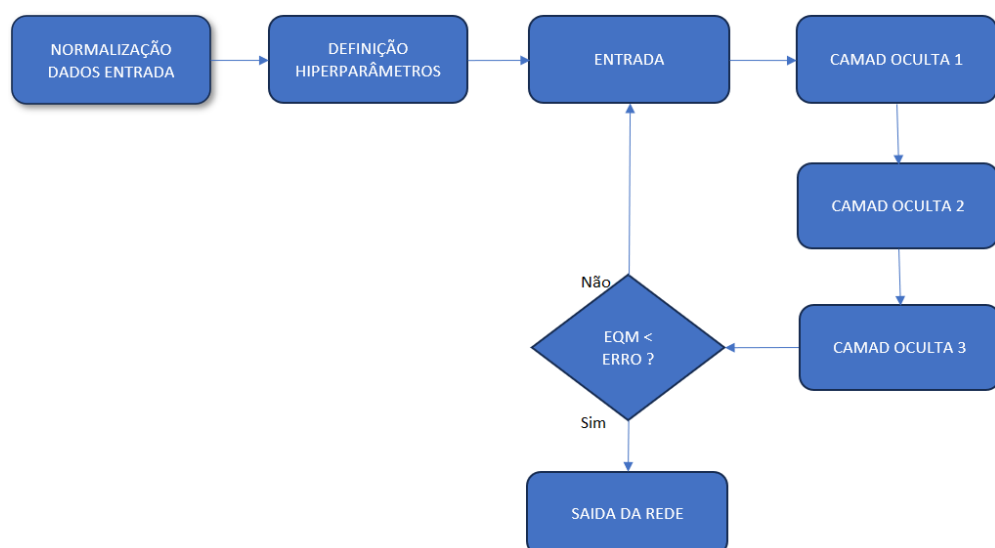
Na Tabela 3, foi estabelecido pseudocódigo com objetivo de representar as etapas constituintes da RNA e serão utilizadas para implementação da rede neural artificial.

Tabela 3. Pseudocódigo - Implementação RNA.

<p>1) NORMALIZAR DADOS</p> <p>2) DEFINIR HIPERPARÂMETROS</p> <ul style="list-style-type: none"> a. Número de épocas. b. Taxa de aprendizagem. c. Número de neurônios. d. O erro. <p>3) TREINAMENTO DA RNA</p> <ul style="list-style-type: none"> a. Definir o método de treino. b. Inserir as entradas da RNA (área e mês) c. Inserir os valores desejados para cada conjunto de entradas. d. Realizar o treinamento da RNA. e. <p>4) VALIDAÇÃO</p> <ul style="list-style-type: none"> a. Plota as saídas da RNA e compara com os valores desejados. b. Cálculo de desempenho da rede (EQM) c. Saída da RNA (estimativa de demanda energética). <p>Fim do Pseudocódigo de Implementação RNA.</p>
--

Fonte: Autoria Própria,2023.

Figura 15. Fluxograma Rede Perceptron MultiCamadas.



Fonte: Autoria Própria,2023.

3.3.1 MÉTODOS DE TREINAMENTO DA RNA

A rede será treinada e avaliada em diversas configurações com objetivo de obter a melhor resposta possível, estas configurações (ou topologias) são descritas a seguir na Tabela 4, sendo os principais elementos desta Tabela: o método de treinamento, a quantidade de neurónicos nas camadas (oculta 01, 02 e 03) e ID do método.

Tabela 4. Configurações das Redes Neurais.

ID MÉTODO	MÉTODOS DE TREINO	QUANTIDADE DE NEURÔNIOS POR CAMADA.		
		CAMADA OCULTA 1	CAMADA OCULTA 2	CAMADA OCULTA 3
LMA1	Levenbeg Maquardt	1	1	1
LMA2	Levenbeg Maquardt	2	2	2
LMA3	Levenbeg Maquardt	3	3	3
.	Levenbeg Maquardt	.	.	.
.	Levenbeg Maquardt	.	.	.
.	Levenbeg Maquardt	.	.	.
LMA30	Levenbeg Maquardt	30	30	30
GD1	Gradiente Descendente	1	1	1
GD2	Gradiente Descendente	2	2	2
GD3	Gradiente Descendente	3	3	3
.	Gradiente Descendente	.	.	.
.	Gradiente Descendente	.	.	.
.	Gradiente Descendente	.	.	.
GD30	Gradiente Descendente	30	30	30
BFGS1	Broyden Fletcher	1	1	1
BFGS2	Broyden Fletcher	2	2	2
BFGS3	Broyden Fletcher	3	3	3
.	Broyden Fletcher	.	.	.
.	Broyden Fletcher	.	.	.

BFGS30	Broyden Fletcher	30	30	30
--------	------------------	----	----	----

Fonte: Autoria Própria,2023.


3.3.1.1 MÉTODO LEVENBERG - MAQUARDT MÉTRICAS

Para análise de desempenho da RNA será avaliado as seguintes componentes: MSE ('Mean Square Error' ou Erro Quadrático Médio) que representa a performance da rede e é modelado pela equação 6.

$$MSE = \frac{1}{N} \sum_{k=1}^N [y(x_k) - d_k]^2 \quad (6)$$

Onde N representa a quantidades de entradas e saídas da RNA, $y(x_k)$ consiste na resposta de saída da RNA e d_k representa o valor desejado como resposta da rede. Para treinamento desta rede, foi realizada diversos treinamentos alterando o número de neurônios da RNA foram defiidas fixas 3 camadas para o treino .Com o objetivo de identificar a melhor configuração para estimativa do volume energético (MWh) , calculada com base no menor MSE.Na Figura 18 serão apresentadas as respostas da RNA PMC – topologia “Levenberg - Marquardt”.

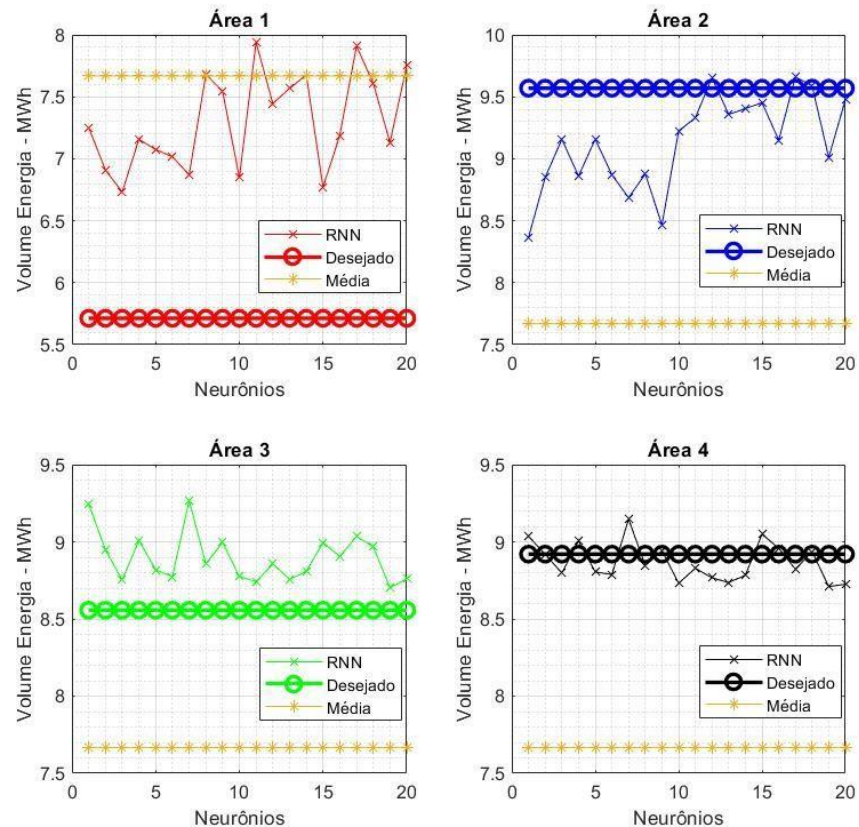
Figura 16. Convergência RNA PMC – Levenberg - Marquardt.



Fonte: Autoria Própria,2023.

Na Figura 16, é possível observar a resposta de convergência da RNA, foram utilizados 60% dos dados para treino, 20% para validação e 10% para testes da RNA, os testes realizados serão apresentados na Figura 17.

Figura 17. Saída RNA PMC – Levenberg - Marquardt.

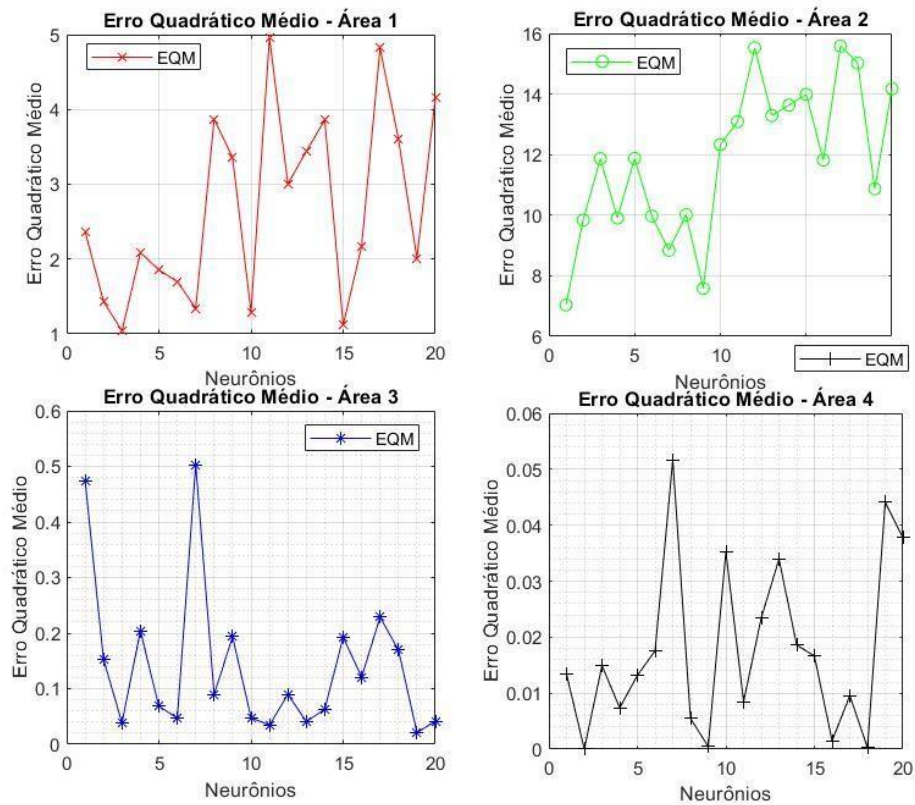


Fonte: Autoria Própria, 2023.

Na figura 17 pode-se observar a resposta da rede neural artificial representada, para diferentes números de neurônios expresso pelo eixo x. O desempenho da rede é mensurado através do MSE, este será apresentado na Figura 18.


A rede com a topologia de treino “Levenberg-Marquadt” (LMA10) apresentou um excelente resultado, nota-se que o menor MSE foi com a modelagem representada pela Figura 19.

Figura 18. Mean Square Error – Levenberg - Marquardt.



Fonte: Autoria Própria,2023.

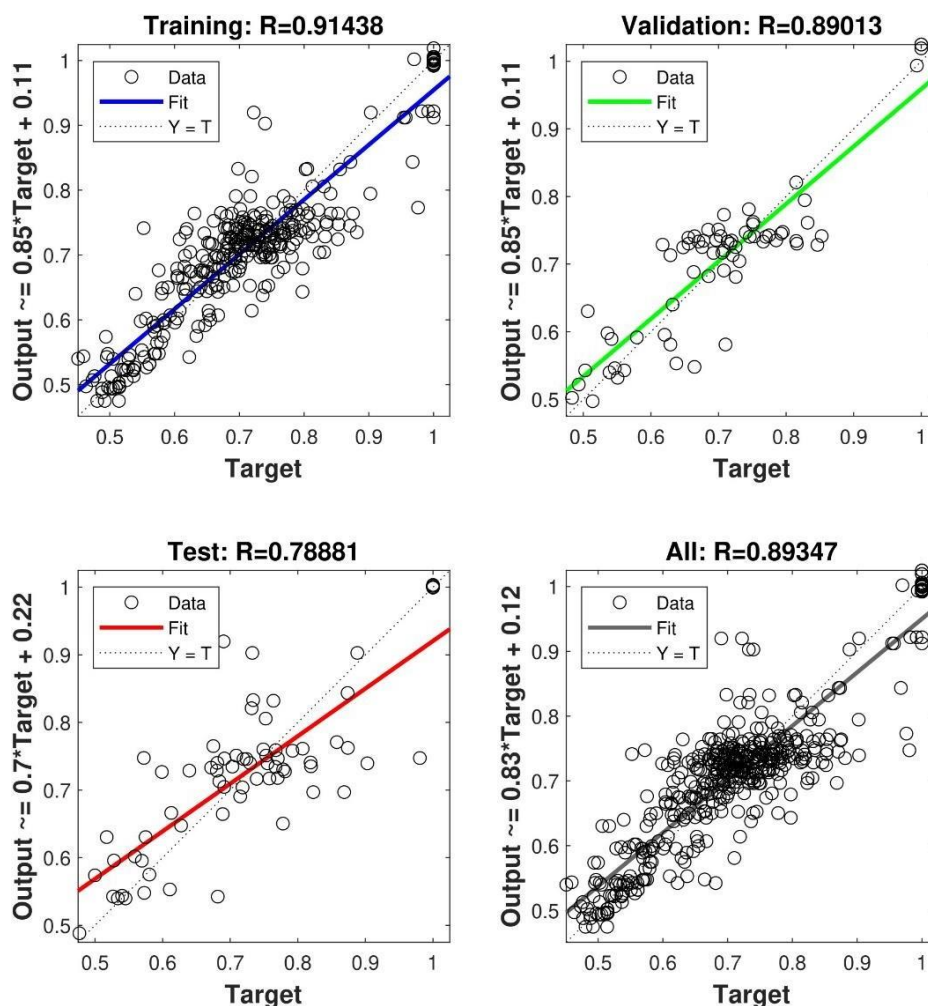
Figura 19. Modelagem RNA PMC – Levenberg - Marquardt.



Fonte: Autoria Própria,2023.

Através da Figura 20, podemos observar a taxa de acerto e aproximação dos dados em relação a saída da rede.

Figura 20. Taxa de Acerto – Levenberg - Marquardt.




Fonte: Autoria Própria, 2023.

3.3.1.2 GRADIENTE DESCENDENTE MÉTRICA.

A avaliação será embasada em métricas extraídas do treinamento da RNA. Obtivemos várias saídas da RNA aumentando o número de neurônios do processo de aprendizado até um total de 30 neurônios e 3 camadas fixas. Com o objetivo de identificar a melhor configuração para estimativa do volume energético (MWh) dos estabelecimentos para atuação no ACL, podemos observar comportamento de convergência da “Rede Neural Artificial – Perceptron Multi Camadas - Método Gradiente Descendente”, na Figura 21.

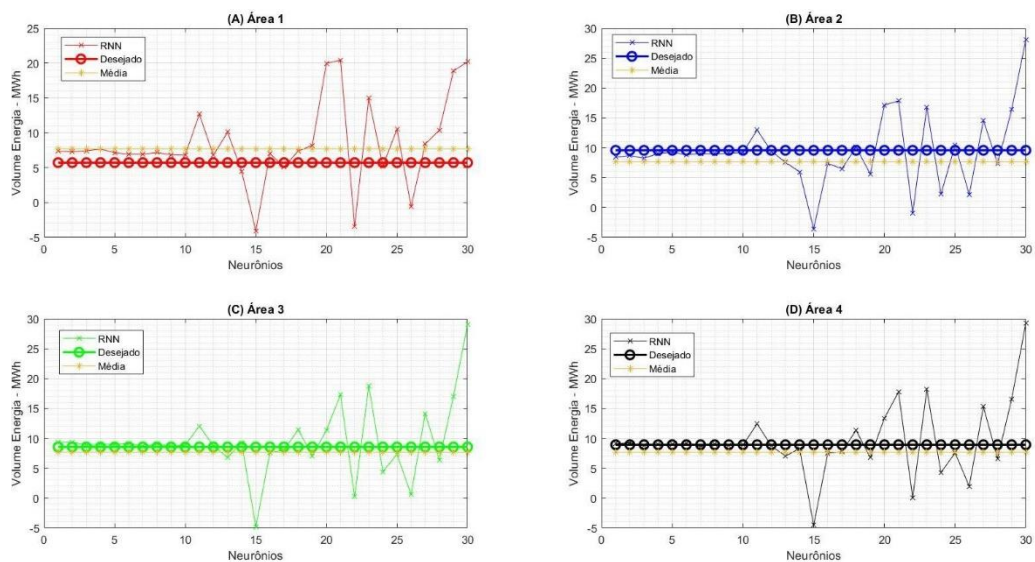
Figura 21. Convergência RNA PMC – Gradiente Descendente.



Fonte: Autoria Própria, 2023.

Na Figura 21, é possível observar a resposta de convergência da RNA, foram utilizados 60% dos dados para treino, 10% para validação e 10% para testes da RNA, os testes realizados serão apresentados na Figura 22.

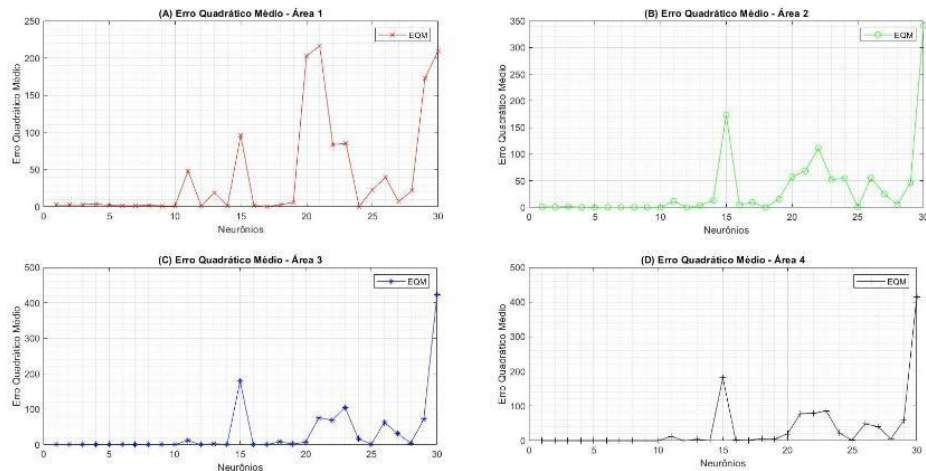
Figura 22. Saída RNA PMC – Gradiente Descendente.



Fonte: Autoria Própria, 2023.

Na Figura 22 pode-se observar a resposta da rede neural artificial representada, para diferentes números de neurônios expresso pelo eixo x. O desempenho da rede é mensurado através do MSE, este será apresentado na Figura 23.


Figura 23. Mean Square Error – Gradiente Descendente.



Fonte: Autoria Própria, 2023.

A rede com topologia de treino “Gradiente Descendente” apresentou um resultado relevante, porém essa modelagem segundo (UFPR, [s.d]) tende a ser uma simplificadora de função sendo indicada uma segunda implementação através do “Método de Newton” ou “Método do Gradiente Conjugado”, isto fica evidente ao observar a Figura 24 .Nota-se que a apesar da convergência a RNA possui uma taxa de acerto muito baixa aproximando-se de uma classificadora linear.


Figura 24. Taxa de Acerto – Gradiente Descendente



Fonte: Autoria Própria, 2023.

A RNA teve seu melhor desempenho apresentando o menor MSE através da modelagem representada pela Figura 25.

Figura 25. Modelagem RNA PMC – Gradiente Descendente.




Fonte: Autoria Própria,2023.

3.3.1.3 BFGS Broyden–Fletcher–Goldfarb Shanno Quasi – Newton - Métricas

A análise será fundamentada em métricas derivadas do processo de treinamento da RNA. Foi explorada diferentes configurações, variando o número de neurônios até um máximo de 30, mantendo constantes as 3 camadas. Durante este processo, buscamos identificar a configuração adequada para a estimativa do volume energético (MWh) dos estabelecimentos no Ambiente de Contratação Livre (ACL). Será destacado, na Figura 26, a trajetória de convergência da Rede Neural Artificial - Perceptron de Múltiplas Camadas - Método Broyden–Fletcher–Goldfarb–Shanno Quasi–Newton.

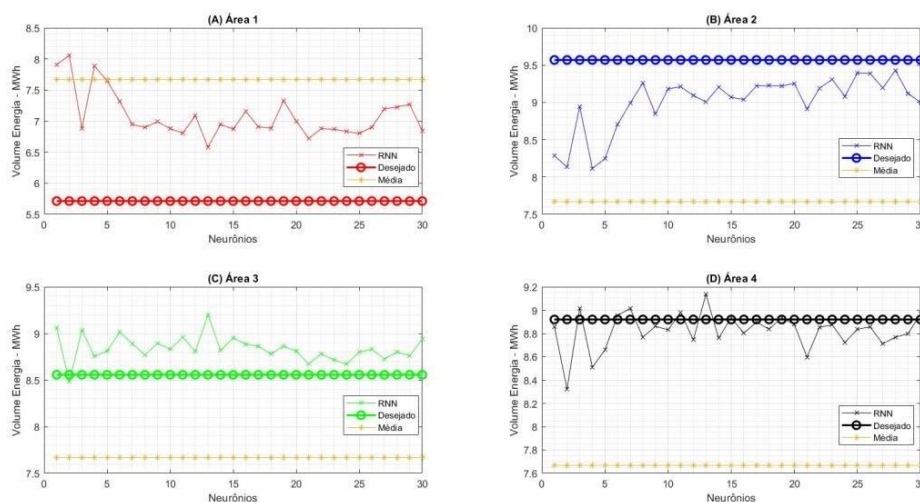
Figura 26. Convergência RNA PMC – Método BFGS.



Fonte: Autoria Própria,2023.

Na Figura 26, é possível observar a resposta de convergência da RNA, foram utilizados 55% dos dados para treino, 35% para validação e 10% para testes da RNA, os testes realizados serão apresentados na Figura 27.


Figura 27. Saída RNA PMC – Método BFGS.



Fonte: Autoria Própria,2023.

Na figura 27 podemos observar o comportamento da rede neural artificial expresso pelo eixo y (Volume Energia MWh), após a mesma ser submetida a diversas configurações de treino aumentando número de neurônios por camada expressa pelo eixo x (Neurônios. O desempenho da rede é mensurado através do MSE, este será apresentado na Figura 28.


Figura 28. Mean Square Error – Método BFGS.



Fonte: Autoria Própria,2023.

Ao analisarmos as métricas de MSE extraídas da rede com o aumento de neurônios por camada, observou-se uma excelente resposta ao atingir a topologia representada pela Figura 29 (BFGS15).


Figura 29. Modelagem RNA PMC – Método BFGS.



Fonte: Autoria Própria,2023.

Através da Figura 30, podemos observar a taxa de acerto e aproximação dos dados em relação a saída da rede.

Figura 30. Taxa de Acerto – Método BFGS.



Fonte: Autoria Própria,2023.

4 CONCLUSÃO E DISCUSSÃO DE RESULTADOS

Com base nas discussões apresentadas ao longo deste trabalho, torna-se possível analisar o desempenho das Redes Neurais Artificiais Perceptron de Múltiplas Camadas (RNA PMC) em diferentes configurações de treinamento. As métricas extraídas nos fundamenta a proferir algumas considerações sobre o desenvolvimento deste estudo.

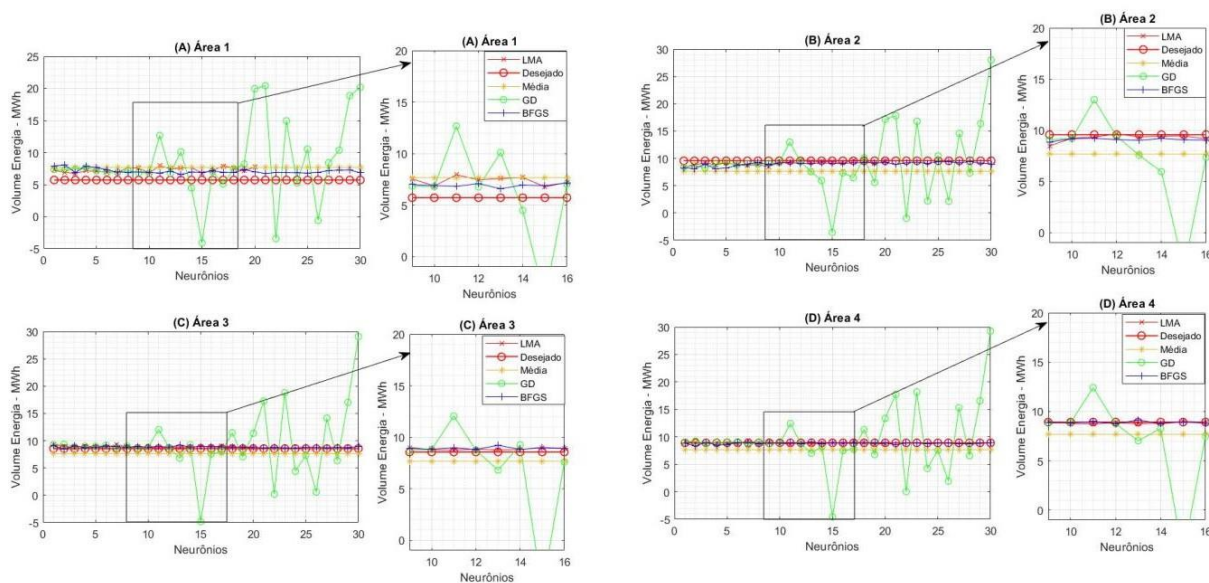
A RNA PMC, configurada com 3 camadas intermediárias e 10 neurônios ID LMA10, utilizando o método de treinamento "Levenberg-Marquardt", apresentou resultados notáveis, conforme detalhado na seção 3.3.1.1. Os resultados revelaram uma excelente taxa de validação dos dados 89%. Esta performance sugere que essa configuração de rede neural pode ser uma escolha eficaz para a implementação de estratégias de estimativa de volume energético para operação de energia elétrica nos Mercados de Curto Prazo (MCP), Médio Prazo (MMP) e Longo Prazo (MLP).

Já a RNA PMC, também configurada com 3 camadas intermediárias e 10 neurônios, treinada por meio do método do Gradiente Descendente, demonstrou convergência. No entanto, sua propensão à linearização e classificação dos dados impediu a obtenção de valores coerentes para seus pesos, resultando em uma taxa de validação menos atrativa, atingindo 39%. Essa abordagem revelou-se ineficaz para a estimativa do volume energético (MWh) nos estabelecimentos em questão.

A RNA PMC configurada com 3 camadas intermediárias e 15 neurônios treinada através do método de Broyden-Fletcher-Goldfarb-Shanno (BFGS), obteve resultados interessantes, este método atingiu o índice de 79% de acerto, mostrando - se uma bom método para comparitivo com estratégia existente.

Por fim, a RNA PMC configurada com 3 camadas intermediárias e 15 neurônios, treinada utilizando o método de Broyden-Fletcher-Goldfarb-Shanno (BFGS), apresentou resultados interessantes, alcançando uma taxa de acerto de 79%. Esse método se mostrou uma alternativa viável e eficaz, proporcionando um bom ponto de comparação com as estratégias existentes. Essa descoberta sugere que o BFGS pode ser considerado como uma abordagem promissora para a configuração de redes neurais destinadas a problemas similares.

Figura 31. Comparativo Métodos LMA – GD – BFGS - Média.



Fonte: Autoria Própria, 2023.

A Figura 31 representa o desempenho das diversas configurações e topologias de treinos da rede neural artificial, neste gráfico é possível analisar o desempenho de acerto das RNA's submetidas.


A topologia treinada através do método de Levenberg Marquardt obteve a melhor resposta em relação aos outros métodos, vale ressaltar que este método apresentou eficácia de 39% superior em relação ao método cálculo médio tradicionalmente utilizado para a tomada de decisão no ambiente de contratação livre e está eficácia possui relação direta com as métricas financeiras que serão abordadas na seção 4.1

4.1 - MÉTODO TRADICIONAL DE ANÁLISE DE VOLUME ENERGÉTICO.

Através da análise de resposta das RNA's, foi possível notar um excelente desempenho, caracterizando um cenário interessante para contratação de um volume energético (MWh) neste ambiente volátil como pode-se observar na Figura 32.

Nesta seção serão abordadas métricas financeiras inerente ao nosso objetivo principal, com intuito de analisar a eficácia desta topologia de rede neural artificial aproximadora comparada com métodos tradicionais empíricos utilizando-se da média em sua tomada de decisão.

Figura 32. Variação PLD 2001 a 2023.



Fonte: Electra,2023.

No “Ambiente de Contratação Livre ACL”, a melhor tomada de decisão é o menor erro possível na compra do volume energético estimado em relação ao real consumido, esta falha submete ao consumidor a cenários catastróficos em prejuízos financeiros, isto ocorre pois as legislações vigentes a modelo contratuais obriga que o consumidor estime corretamente o volume de energia a ser comprado e esta transação é celebrada através do contrato de compra de energia homologado junto a CCEE, caso o consumidor chegue ao fim do contrato e não tenha utilizado todo o seu volume energético (MWh), este é liquidado pela câmara de comercialização ao Preço do PLD que é representado pela Figura 34, podendo acarretar enormes prejuízos financeiros.

Um outro ponto é quando o consumidor utiliza todo seu volume de energia antes do término do seu contrato, obrigando-o a comprar energia no mercado de curto prazo, este cenário também pode ser prejudicial pois assim estará sujeito a volatilidade do PLD e a taxa SPREAD que representa estratégia comerciais para venda de energia de cada agente comercializador do mercado livre, este está ligado ao poder de negociação destes agentes. Ambos cenários são desfavoráveis pois estão passivos de grandes prejuízos financeiros, na Figura 33 pode-se observar valores (R\$) bases para compra de energia no mercado livre de energia.

Na Figura 35 é possível identificar as topologias as quais o consumidor pode fazer sua operação de compra de volume energético, sendo caracterizada em duas configurações “Produto Incentivada I5” e “Produto Convencional”, estas topologias possuem diferentes valores unitários (R\$) para compra do volume energético (MWh)

para diferentes configurações como contratos de curto prazo MCP , mercado de médio prazo MMP e mercado de longo prazo MLP, além disto estas são representadas por duas vertentes “I5 Icentivada” onde nesta configuração o consumidor possui desconto de 50% do seus custos com a taxa TUSD (Tarifa Uso do Sistema de Distribuição) , as incentivadas são caracterizadas por serem energia comercializadas por Usinas Fotovoltaicas (UFV) , Usina Eólicas (EU) , Biomassa , Pequenas Centrais Hidrelétricas (PCH’s) , para estes são celebrados “Contratos de Compra de Energia Elétrica Incentivada Especial (CCEEIE). (CCEE,2012).

Figura 33. Indicativo Preço Volume Energético (MWh).

Indicativo de preços

Preço FLAT – Válido até 14/11/23

*Produto Incentivada - I5							
2023	2024	2025	2026	2027	2028	2029	2030
120							
119	125						
118	124	134					
117	123	133	144				
116	122	132	143	151			
115	121	131	142	150	156		
115	121	131	142	150	156	159	
114	120	130	141	149	155	158	162

*Produto Convencional							
2023	2024	2025	2026	2027	2028	2029	2030
90							
89	91						
88	90	104					
87	89	103	113				
86	88	102	112	121			
85	87	101	111	120	126		
85	87	101	111	120	126	131	
84	86	100	110	119	125	130	134

**Produto Varejista							
2023	2024	2025	2026	2027	2028	2029	2030
157	167	178	177	193	197	200	217

Fonte: CEMIG,2023.

Já o nicho convencional remete-se a compra do volume energético de Grandes Usinas Hidrelétricas, este modelo não garante desconto na tarifa (TUSD), estes cenários garantem ao consumidor estratégias de gestão e eficiência energética e fomenta o mercado competitivo.

Para um modelo de negócio de compra de energia neste ambiente, foi adotado a configuração I5 no período de de um ano, onde este representa o Mercado de Médio Prazo, através desta configuração serão comparadas as métricas extraídas das saídas estimadas das RNA's que apresentaram relevância em seu resultado com

intuito de validar o objetivo deste trabalho. Na Figura 34 e apresentado cotação do PLD para efeitos de cálculo e discussão das métricas financeiras.

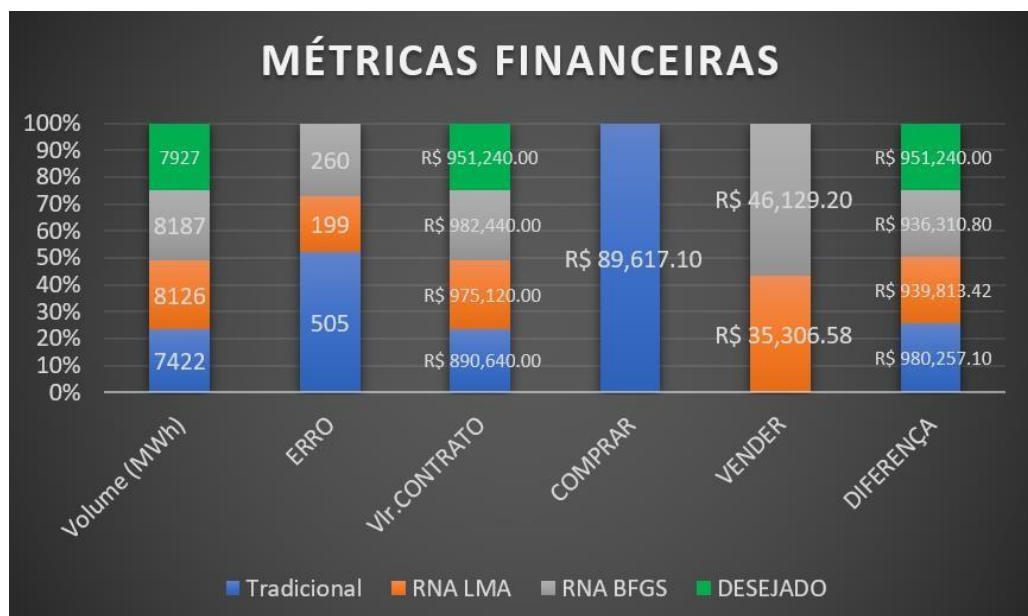
Figura 34. PLD - 14/11/2023.



Fonte: Electra,2023.

A partir deste cenário será comparado através da Figura 35 o comportamento e desempenho financeiros das estratégias abordadas com intuito de validação deste trabalho.

Figura 35. Comparação Métricas Financeiras.



Fonte: Autoria Própria,2023.

A Figura 35, representa o desempenho financeiro do cenário abordado. Esta figura nos traz resultados positivos e viabiliza a utilização da Rede Neural Artificial – Perceptron Multicamadas configurada na topologia 3 camadas e 10 Neurônios treinada e validada pelo método de treino de Levenberg Marquardt como uma excelente ferramenta para estimativa de volume energético e contratação de energia elétrica no mercado livre de energia (ACL).

5 CONCLUSÃO.

A análise do desempenho das Redes Neurais Artificiais Perceptron Multicamadas (RNA PMC) em configurações diversas revelou resultados promissores, especialmente ao considerar o contexto volátil do Mercado Livre de Energia (ACL). A utilização destas redes proporcionou um cenário favorável para a contratação de volume energético (MWh).

Ao adentrar na análise financeira, este trabalho focalizou a tomada de decisões no ACL, enfatizando a necessidade de estratégias eficazes para mitigar prejuízos significativos. O ambiente competitivo e dinâmico do mercado livre implica desafios, dentre eles, este estudo destacou que a melhor tomada de decisão reside em garantir o menor erro possível na compra do volume energético (MWh) estimado, em relação ao real consumido. Tanto em cenários de venda de excedente de energia (ter estimado mais energia do que consumido) quanto em situações de compra de um volume energético faltante (ter estimado menos energia do que o realizado), o consumidor se expõe a riscos financeiros devido à volatilidade nos preços deste cenário.

Os cenários de potenciais prejuízos financeiros foram detalhadamente abordados, considerando a falha na estimativa do volume de energia, o que pode resultar em transações desvantajosas, influenciadas pelo Preço de Liquidação das Diferenças (PLD) e a taxa SPREAD. As estratégias comerciais foram representadas por topologias específicas, como "Produto Incentivada I5" e "Produto Convencional", cada uma com suas peculiaridades em termos de descontos e vantagens.

A comparação das métricas financeiras, conforme demonstrado nas Figuras 35, 36 e 37, forneceu uma visão abrangente do comportamento e desempenho das

estratégias analisadas. Notavelmente, a topologia de RNA PMC configurada com 3 camadas e 10 neurônios, treinada pelo método de Levenberg Marquardt, mostrou-se como uma ferramenta eficiente para a estimativa de volume energético e a contratação de energia elétrica no ACL.

Diante dos resultados obtidos, este trabalho não apenas valida a eficácia da abordagem proposta, mas também destaca a importância da implementação de estratégias precisas e adaptáveis para o sucesso operacional em um ambiente tão dinâmico quanto o Mercado Livre de Energia.

REFERÊNCIAS

MACHADO, M. História do Mercado Livre de Energia no Brasil. Disponível em:

<<https://copelmercadolivre.com/historia-do-mercado-livre-de-energia-no-brasil/>>.

Acesso em: 11 jun. 2023.

CASADEI, J. O direito de escolher o fornecedor de energia vale bilhões ABRACEEL.

Disponível em: <<https://abraceel.com.br/biblioteca/artigos/2023/03/o-direito-de-escolher-o-fornecedor-de-energia-vale-bilhoes/>>. Acesso em: 11 jun. 2023.

CARTILHA MERCADO LIVRE DE ENERGIA ELÉTRICA. [s.l: s.n.]. Disponível em:

<https://abraceel.com.br/wp-content/uploads/2019/05/ABRACEEL_process_230519.pdf>.

ZANCHETTIN, C.; LUDERMIR, T. B. Sistemas neurais híbridos para reconhecimento de padrões em narizes artificiais. Sba: Controle & Automação Sociedade Brasileira de Automatica, v. 16, n. 2, p. 159–172, jun. 2005.

Redes Neurais Artificiais. Disponível em:

<https://sites.icmc.usp.br/andre/research/neural/>, set. 2016.

ESKADA | Cursos Abertos da UEMA. Disponível em:

<<https://eskadauema.com/mod/book/tool/print/index.php?id=1651>>. Acesso em: 11 jun. 2023.

MATOS, D. Normalização em Machine Learning. Disponível em:

<<https://www.cienciaedados.com/normalizacao-em-machine-learning/>>. Acesso em: 30 out. 2023.

LARSON, RON. e FARBER, BETSY. Estatística Aplicada. Editora Pearson, 4ed. São Paulo, 2009.

ADERALDO, K.; ADEMIR, B.; RIBEIRO, A. O Método de Levenberg-Marquardt para o Problema de Quadrados Mínimos não Linear. [s.l: s.n.]. Disponível em:

<<https://eventos.ufpr.br/smne/SMNE2017/paper/viewFile/548/230>>.

Gonçalves, L. M. G., Gonçalves, W. N., & Silva, L. A. F. (2010). "Uma análise comparativa entre métodos de treinamento de redes neurais artificiais para previsão de séries temporais." Simpósio Brasileiro de Redes Neurais.

FPR, 2019. Disponível em: <<http://cursos.leg.ufpr.br/ML4all/apoio/Gradiente.html>>.

MUKHERJEE, I.; ROUTROY, S. Comparing the performance of neural networks developed by using Levenberg–Marquardt and Quasi-Newton with the gradient descent algorithm for modelling a multiple response grinding process. Expert Systems with Applications, v.39, p.2397–2407, 2012.

HARRIS, Chris - Electricity markets : pricing, structures and economics. Chichester : John Wiley & Sons, 2006. COTA: 620.9 HAR.

FIRJAN. Disponível em:<<https://www.firjan.com.br/firjan/peq/temas/energia.htm>>.

Acesso em: 12 nov. 2023.

ENGIE. Disponível em:

<https://www.alemndaenergia.engie.com.br/angela-oliveira-mercado-livre-de-energia/#:~:text=Desde%20janeiro%20de%202023%2C%20com,a%20demanda%20de%20500%20kW>.

ANEEL.Regras de Comercialização. Disponível em: <<https://www.gov.br/aneel/pt-br/assuntos/mercado>>.

Nikola Tesla. Disponível em: <<https://mundoeducacao.uol.com.br/fisica/nikola-tesla.htm#:~:text=Iniciou%20o%20curso%20de%20Engenharia>>. Acesso m: 12 nov. 2023.

SILVA.2020 Disponível em <https://abraceel.com.br/blog/2020/01/quando-surgiu-o-mercado-livre-de-energia-no-brasil/>

FALCÃO, C. I. S. Estudo do mercado livre de energia elétrica. Revista Científica Multidisciplinar Núcleo do Conhecimento, v. 04, n. 08, p. 35–65, 20 ago. 2020.

SILVA, I. N.; SPATTI, D. H.; FLAUZINO, R. A. Redes Neurais Artificiais para engenharia e ciências aplicadas: curso pratico. São Paulo: Artliber, 2010.

SIMON, H. Redes Neurais Artificiais princípios e prática. 2ed. São Paulo: Bookman, 2000.

BICHELS, Arley. (2018). Sistemas Elétricos de Potência. Métodos de Análise e Solução. Editora da Universidade Tecnológica Federal do Paraná

CCEE. (2012). Cartilha Energia Incentivada Especial Compra e Venda de Energia Elétrica Treinamento Geração Hidráulica.

LIRA Saschiko A. (2004). Análise de Correlação Abordagem Teórica e Construção dos Coeficientes com Aplicações. UTFPR 2004.

Capítulo II – Desenvolvimento de um Estimador de Velocidade *Sensorless* para Motor CC utilizando Redes Neurais

Danilo Ferreira Fontoura ⁴

Renato Kazuo Miyamoto ⁵

Wesley Candido Silva ⁶

Victor Emanuel Correia De La Rosa ⁷

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.

Development of a *Sensorless* Speed Estimator for a DC Motor Using 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.

⁴ Engenheiro Eletricista. UniSenaiPR - Campus Londrina.

⁵ Doutor em Engenharia Elétrica. UniSenaiPR - Campus Londrina.

⁶ Especialista. UniSenaiPR - Campus Londrina.

⁷ Especialista. UniSenaiPR - Campus Londrina.

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.

1. 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. Consequentemente, 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.



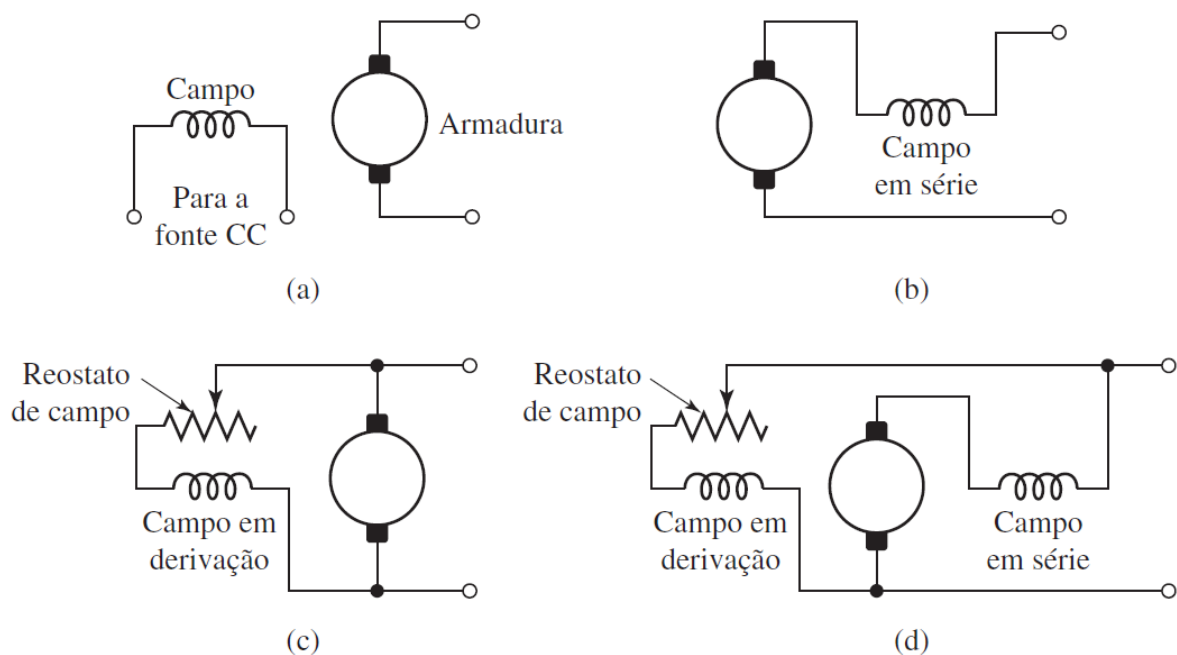
Fonte: Umans (2014, p. 405).

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).

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).

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.

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.

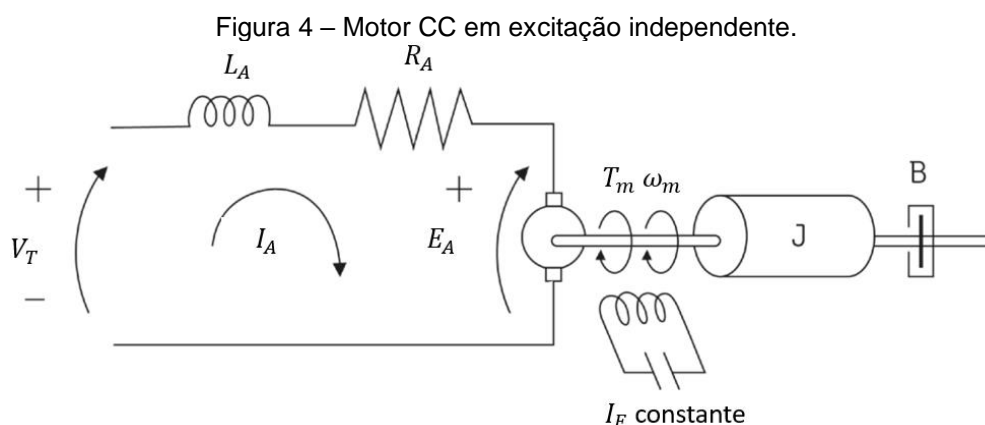
A excitação independente oferece um controle mais preciso sobre o desempenho do motor, proporcionando uma faixa mais ampla de controle de velocidade e torque. Esse tipo de configuração é especialmente útil em sistemas que exigem variações frequentes e rápidas de velocidade ou que operam sob condições 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. 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. 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).

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):

$$T_m(s) = K \cdot I_A(s) \quad (6)$$

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

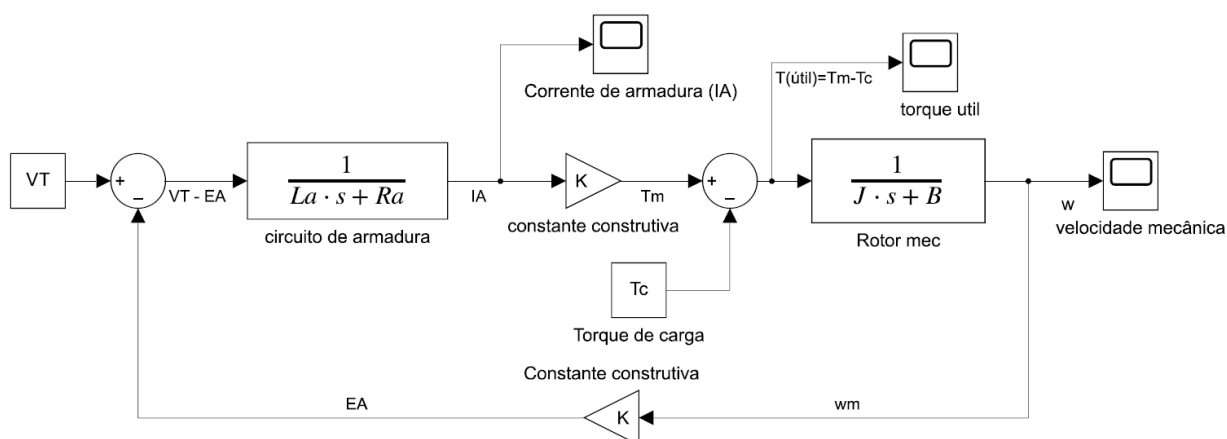
$$T_m = J \cdot \frac{d\omega_m}{dt} + B\omega_m \quad (6)$$

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.

2. 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).

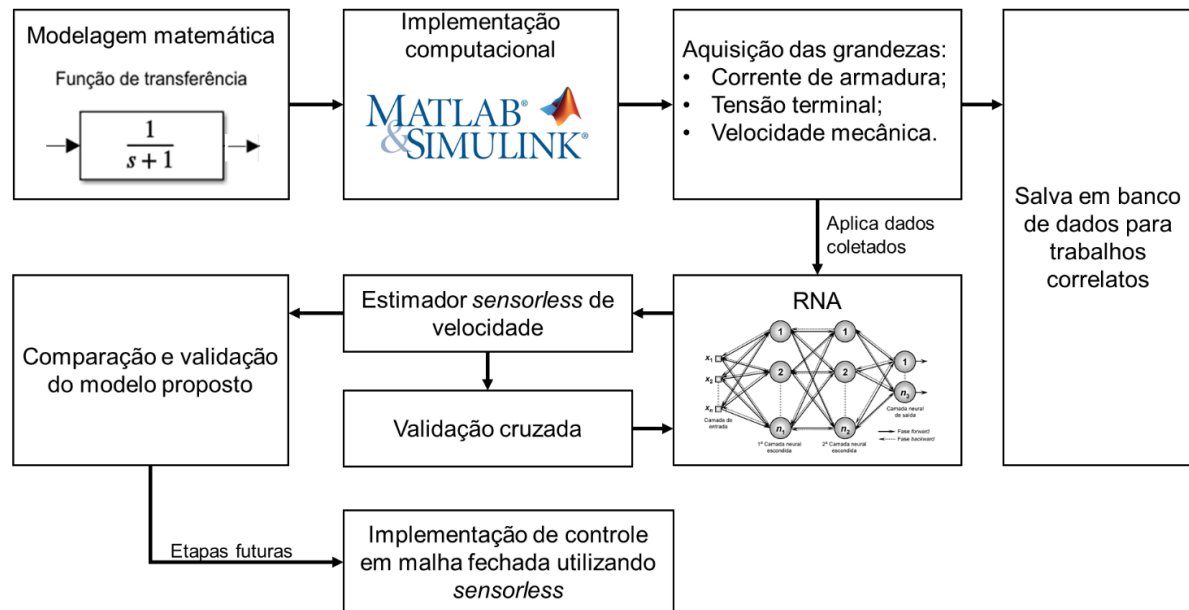
Para usar a PMC aplicada a um estimador de velocidade de motor CC foi necessário fazer a coleta de dados de entrada (como tensão e corrente) e saída (velocidade do motor). Esses dados são utilizados para treinar a rede neural, que aprende a relação entre as entradas e a saída do sistema. Após o treinamento,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

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.

Figura 7 – Esquemático da metodologia utilizada nesta pesquisa.



Fonte: Elaborado pelos autores.


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).

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.

Figura 8 – Diagrama Simulink da implementação computacional da MCC.



Fonte: Elaborado pelos autores.

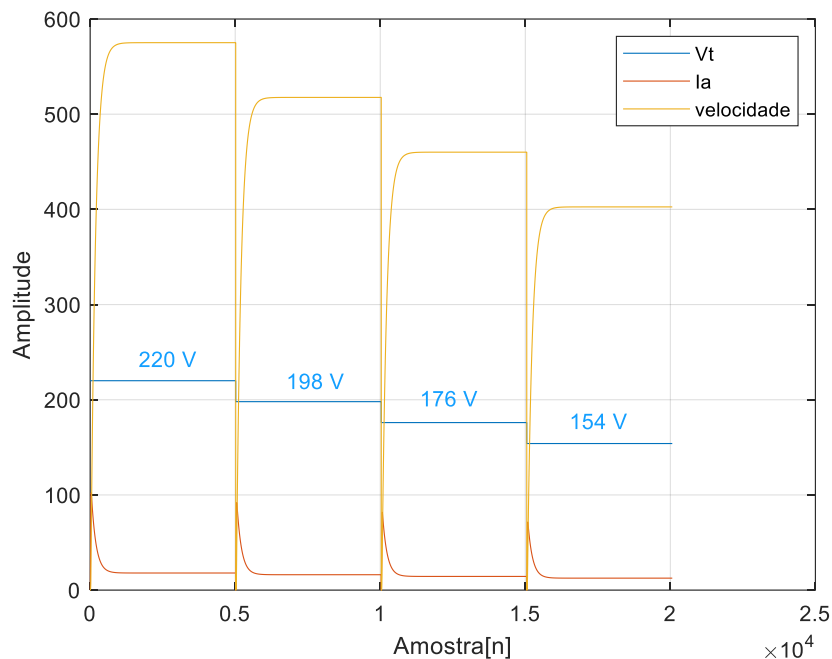
Tabela 1 – Parâmetros do circuito equivalente.

Parâmetro	Valor
Resistência de armadura (R_a)	2Ω
Indutância de armadura (L_a)	$0,01H$
Constante condutiva (K)	$0,32$
Momento de inércia (J)	$0,01 \text{ kg.m}^2$
Coeficiente de atrito (B)	$0,01 \text{ N.m/rad/s}$
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.

Figura 9 – Coleta de dados para treinamento da RNA.



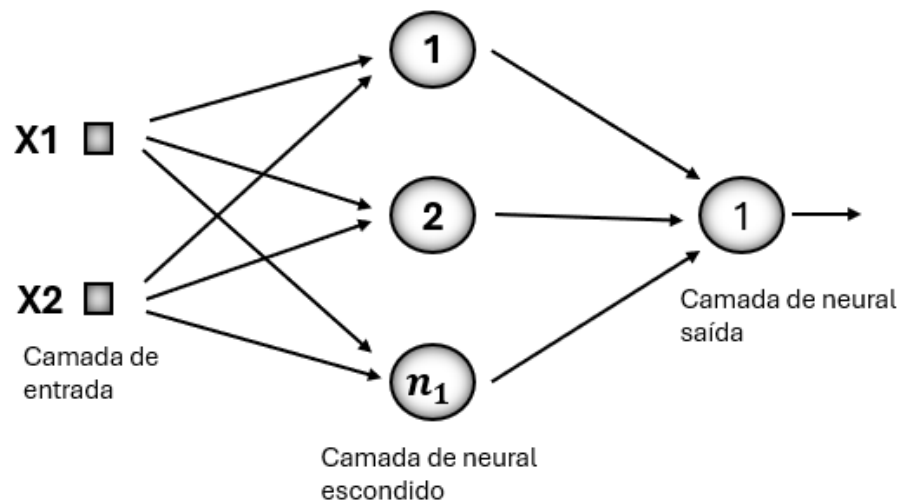
Fonte: Elaborado pelos autores.

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.

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.

Na figura, X_1 e X_2 são as entradas da rede: tensão terminal de armadura (V_T) 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.

Figura 10 – Topologia genérica da PMC.



Fonte: Elaborado pelos autores.

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.

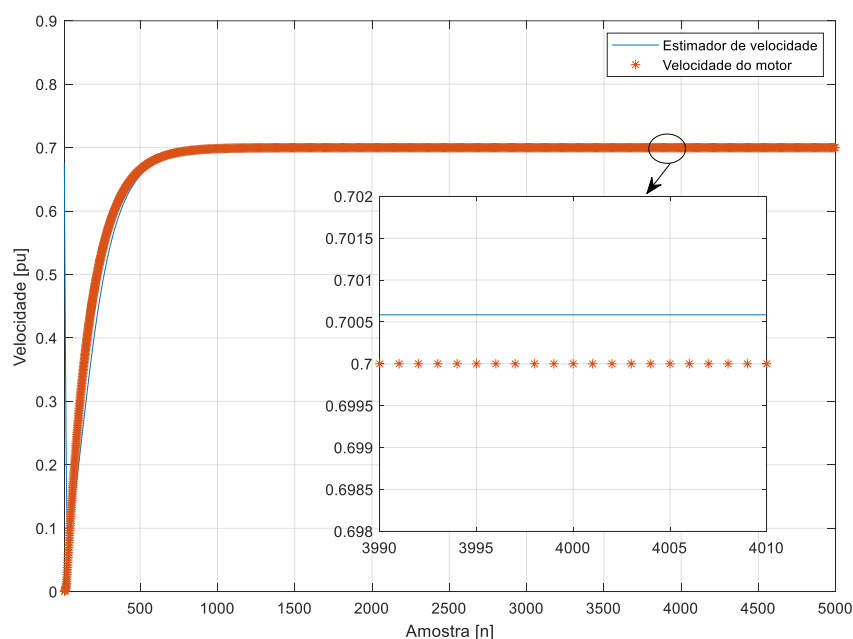
No contexto de simulação de motores CC, a validação pode ser realizada comparando a saída da rede (velocidade prevista) com os dados coletados do Simulink.

3. 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.

4. 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

Capítulo III – Análise Comparativa entre Controladores PI e PI-Neural em Sistemas Térmicos

John Everson Rodrigo Mello Jayme⁸

Renato Kazuo Miyamoto⁹

Leonardo Yuji Ishizaki¹⁰

RESUMO

Os controladores PI são amplamente empregados no setor industrial. No entanto, enfrentam desafios significativos no controle de sistemas com consideráveis atrasos de tempo e na busca por ganhos ideais. Essa abordagem requer modelos matemáticos e sua robustez é afetada por variações nos parâmetros do processo. Este estudo propõe uma análise comparativa entre um controlador PI convencional e um controlador PI-Neural aplicado a um sistema térmico de uma planta didática Smar PD3-P. A função de transferência da planta foi determinada por meio de experimentos de aplicação da resposta ao degrau de tensão. Após a determinação da função de transferência, um controlador PI foi sintonizado utilizando o método de Dorf e Bishop. Foram realizados ensaios experimentais no sistema com mudanças bruscas na temperatura de referência para avaliar o desempenho do controle PI. Posteriormente, um controlador PI-neural foi implementado, utilizando uma estratégia de sintonia que não necessita de modelagem do sistema. Os resultados demonstraram uma melhoria de aproximadamente 15% no tempo de estabilidade e uma melhor linearidade em comparação com o controle clássico PI.

Palavras-chave: PI-Neural. Controle clássico. Métodos de sintonia. Identificação de Sistemas.

Comparative Analysis Between PI and PI-Neural Controllers in Thermal Systems

ABSTRACT

PI controllers are widely employed in the industrial sector. However, they face significant challenges in controlling systems with considerable time delays and in the search for optimal gains. This approach requires mathematical models, and its robustness is affected by variations in process parameters. This study proposes a comparative analysis between a conventional PI controller and a PI-Neural controller applied to a thermal system of a Smar PD3-P didactic plant. The transfer function of the plant was determined by means of experiments of application of the response to the stress step. After determining the transfer function, a PI controller was tuned using the Dorf and Bishop method. Experimental tests were carried out on the system with sudden changes in the reference temperature to evaluate the performance of the PI control. Subsequently, a PI-neural controller was implemented, using a tuning strategy that does not require system modeling. The results demonstrated an improvement of approximately 15% in stability time and a better linearity compared to the classic PI control.

Key words: PI-Neural. Classic control. Tuning methods. Systems Identification.

⁸ Engenheiro Eletricista. UniSenaiPR - Campus Londrina.

⁹ Doutor em Engenharia Elétrica. UniSenaiPR - Campus Londrina.

¹⁰ Mestre em Engenharia Elétrica UniSenaiPR - Campus Londrina.

1 INTRODUÇÃO

O setor industrial apresenta constante atualização de seus processos produtivos em busca de melhoria em sua produtividade para se manter competitivo no mercado. Nesse cenário, o controle e a automação de processos é uma das áreas fundamentais para aumentar a rentabilidade das unidades, e pode contribuir significativamente no tempo e no desempenho desses processos (CAMPOS; TEIXEIRA, 2010).

A automação de processos fundamenta-se na aplicação de tecnologia para otimizar e controlar tarefas de forma eficiente e precisa, utilizando controladores. Os controles se dividem em sistemas de malha aberta e malha fechada. Um sistema de malha aberta é um sistema de controle onde a saída não é comparada com a referência para fazer ajustes durante o processo. Em um sistema de malha fechada ocorre uma realimentação que compara a saída com a entrada através de um valor de referência tornando o controle mais preciso e menos sensível (GARCIA, 2021).

O controle em malha fechada do tipo PI é um método tradicional de controle no qual são definidos os ganhos proporcional e integrativo, com o objetivo de permitir que o sistema opere dentro de uma dinâmica aceitável (ASTROM; HAGGLUNG, 1995). No entanto, essa estratégia de controle apresenta dificuldades de ajuste de seus parâmetros de sintonia, justificado pelo mau dimensionamento de projeto ou devido a inexperiência de seus operadores.

De acordo com Bialkowski (1993), Ender (1993), McMillan (1995) e Hersh e Johnson (1997), o setor industrial de papel e celulose possui mais de 2000 malhas de controle. Desse total, apenas 20% possuem um bom funcionamento e 80% possuem desempenho insatisfatório. Dentre os que possuem desempenho não satisfatório, 30% são devido a ajustes indevidos do controlador; 30% devido a problemas de válvulas de controle; e 20% devido a problemas de projeto de processo ou sistema de controle (YU, 2013).

Segundo Ender (1993), na indústria de processos um total de 30% das malhas opera no modo manual, 20% dos controladores usam ajustes de fábrica e 30% apresentaram problemas no sensor e válvula de controle. Nas indústrias de processos químicos metade das válvulas necessitam de manutenção precoce devido aos ajustes errôneos (McMILAN, 1994). Na indústria de manufatura de processos, engenheiros e

gerentes citaram o ajuste do controlador como um problema difícil (HERSH; JOHNSON, 1997; YU, 2013).

Embora amplamente aplicados, os controladores PI frequentemente apresentam respostas transitórias deficientes e podem não fornecer robustez adequada em relação às variações nos parâmetros do processo. No cenário atual, as tecnologias de otimização de controles estão ganhando destaque no campo da inteligência artificial, como por exemplo as Redes Neurais Artificiais (RNAs) (FERREIRA; DE MOARES, 2016). Embora os sistemas de controle baseados em RNAs tenham sido extensivamente testados em simuladores computacionais, sua implementação em testes práticos ainda apresenta desafios significativos.

Uma rede neural é um sistema projetado para emular a forma como o cérebro humano executa tarefas específicas ou responde a estímulos de interesse (HAYKIN, 2001). Ela pode ser considerada um sistema adaptativo que fundamenta-se em um modelo matemático inspirado na estrutura de seres vivos, oferecendo uma maneira simplificada de emular o funcionamento do cérebro humano em computadores (FERREIRA; DE MOARES, 2016).

A motivação central deste trabalho consiste em realizar uma análise comparativa entre um controlador PI convencional e um controlador PI-Neural aplicado a um sistema térmico de uma planta didática Smar PD3-P. Primeiramente, a função de transferência da planta foi obtida por meio da resposta ao degrau a uma entrada de tensão. Após a obtenção da função de transferência, um controlador PI foi ajustado usando a abordagem proposta por Dorf e Bishop. Ainda, foi implementado um controlador PI-neural que empregou uma estratégia de sintonia que dispensou a necessidade de modelagem do sistema.

2 FUNDAMENTAÇÃO TEÓRICA

Atualmente, os sistemas de controle automático estão amplamente presentes em diversos setores industriais, como qualidade de produtos, linhas de montagem, máquinas operatrizes, tecnologia espacial, defesa, transporte, energia e robótica. Eles desempenham um papel crescente na evolução da civilização e tecnologia modernas, influenciando praticamente todos os aspectos de nossas atividades cotidianas (Faccin, 2004).

Com base nos dados coletados, os sistemas de controle utilizam algoritmos e lógica de controle para tomar decisões e emitir comandos para dispositivos e atuadores, como válvulas, motores, aquecedores etc., a fim de ajustar e manter as variáveis do processo dentro de faixas desejadas. O controle em malha fechada do tipo PI é um método clássico de regulação no qual os ganhos proporcional e integral são ajustados com o intuito de garantir que o sistema funcione dentro de uma resposta dinâmica adequada.

2.1. Controlador PI convencional

O controle Proporcional-Integral (PI) representa uma das estratégias de controle mais amplamente reconhecidas. Sua eficácia prontamente comprovada, aliada à sua simplicidade de implementação, estabelece-o como uma das abordagens mais comuns nos processos industriais de primeira ordem. O conceito fundamental à aplicação de um controlador PI precede na leitura de um sensor, na comparação desse valor com uma referência, na posterior avaliação da resposta do atuador por meio dos cálculos dos componentes proporcional e integral, resultando na combinação desses dois elementos para estabelecer a saída desejada, conforme a equação (1) (Oliveira, 2014).

$$u(t) = k_p e(t) + \frac{k_p}{T_i} \int_0^t e(t) dt \quad (1)$$

onde:

$u(t)$ é a saída do controlador;

K_p é o ganho proporcional;


$e(t)$ é o erro;

T_i é o tempo integrativo.

Segundo Ogata (2003), na maioria das vezes, os controladores usados nas indústrias são configurados no local, onde se observa como o sistema responde. Quando essas configurações são feitas por operadores, os resultados podem ser afetados por falta de atenção para certas situações, falta de reconhecimento de fatores externos que podem afetar o controle ao longo do tempo e imprecisões nas ações, o que pode fazer com que as configurações não funcionem bem.

Devido a essa necessidade, diversos métodos de sintonia têm sido divulgados na literatura. Conseqüentemente, têm surgido abordagens automáticas para a proposição de regras de sintonia. O controlador PI atua em malha fechada em que a variável a ser controlada é continuamente medida por um sensor localizado no processo. Essa medição é então fornecida ao controlador, que gera um sinal de erro atuante, representando a diferença entre a saída atual e o valor de referência desejado (*setpoint*), conforme a Figura 1 (SILVA, 2021).

Figura 1 – Modelagem do controlador PI



Fonte: autoria própria (2023)

O controlador age com o objetivo de minimizar esse erro atuante, ajustando a entrada do sistema de acordo com a diferença identificada, buscando manter a saída o mais próxima possível do valor de referência.


2.2. Métodos de sintonia para controlador PI

A origem dos controladores PI remonta ao trabalho pioneiro de Ziegler e Nichols, em 1942, quando propuseram o primeiro método de ajuste para esses controladores. Esse método trouxe consigo uma transformação significativa na abordagem de controle de sistemas, estabelecendo as bases para a estabilização e controle de uma vasta gama de processos industriais. A notável eficácia desses controladores é evidenciada pelo fato de que podem ser aplicados com sucesso em aproximadamente 90% dos cenários industriais existentes (Saraiva, 2011, [s.d.]).

O Método de Ziegler-Nichols para sistemas de primeira ordem com a resposta ao degrau é uma técnica de sintonia clássica para controladores PI. Primeiro, um sinal de entrada degrau é aplicado ao sistema, e a resposta do sistema é observada. A curva de reação é analisada, representando a resposta do sistema ao longo do tempo, com foco no tempo de atraso (L) e no tempo de subida (T) conforme a Figura 2. Com base nesses parâmetros da curva de reação, podem ser aplicadas regras empíricas da Tabela de Ziegler-Nichols para determinar os valores iniciais do ganho proporcional

(Kp) e do tempo integral (Ti) do controlador PI. A escolha dos valores de Kp e Ti depende do grau de oscilação aceitável no sistema, com opções que variam de uma sintonia conservadora a uma sintonia mais agressiva.


Figura 2 – Método de Ziegler Nichols para curva de reação



Fonte: Ogata, Katsuhiko, 2010

O método CHR desenvolvido em 1952 por K. L. Chien, J. A. Hrones e J. B. Reswick, sendo o pioneiro a modelar um sistema de primeira ordem com tempo morto, propõe dois critérios de desempenho, a resposta rápida sem sobrevalor (CHR- 0%) e outra com 20% sobrevalor (CHR – 20%), possui características diferenciadas tanto na mudança de setpoint quanto na perturbação da carga (Saraiva,2011, [s.d.]). Já Broída sugere a modelagem de um processo de *n*-ésima ordem através da utilização de uma curva de primeira ordem com tempo de atraso. Nesse contexto, esse modelo representa uma função de transferência de primeira ordem, onde se observa um intervalo de tempo entre os pontos A (representando 28% da amplitude) e B (representando 40% da amplitude), conforme Figura 3.

Figura 3 – Método de Broída para Curva de reação



Fonte: <http://www.abenge.org.br/cobenge/legado/arquivos/5/Artigos/128939.pdf>

A Tabela 1 é um registro dos cálculos efetuados com relação aos métodos de sintonia adotados. Especificamente, para a determinação dos valores de T e L, optou-se pelo método de Broída, uma decisão que se fundamenta na ausência de tempo morto nas curvas de reação.

Tabela 1 – comparativos de Métodos de sintonia

Método	Kp	Ti	Ki
Ziegler Nichols	$0.9*(T/L)$	$3*L$	Kp/Ti
Chien-Hrones-Reswick	$(0.6*T)/(K*L)$	$4*L$	Kp/Ti
Chien-Hrones-Reswick 20%	$(0.95*T)/(K*L)$	$1.4*T$	Kp/Ti
Dorf e Bishop	$0.6*(K)$		$(1.2*K)/T$

Fonte: autoria própria (2023)

As redes neurais têm emergido como uma alternativa promissora ao tradicional controle Proporcional-Integral (PI) em diversos contextos. Essa abordagem se baseia na capacidade das redes neurais artificiais de aprender a partir de dados e adaptar seu comportamento de acordo com o ambiente, tornando-as particularmente adequadas para sistemas complexos e não-lineares.

2.3. Redes Neurais Artificiais


Em sua forma mais ampla, uma rede neural é um sistema projetado para emular o modo como o cérebro aborda uma tarefa específica. Isso é tipicamente alcançado por meio da implementação de componentes eletrônicos ou da simulação computacional (FERREIRA; DE MOARES, 2016). Assim, as redes neurais artificiais podem ser definidas como um conjunto de ferramentas computacionais inspiradas no sistema nervoso de seres vivos (SILVA; SPATTI; FLAUZINO, 2010).

Em vez de depender de modelos matemáticos precisos, as redes neurais podem aprender a controlar um sistema através de um processo de treinamento, ajustando-se dinamicamente às variações e incertezas que podem desafiar o controle PI convencional. Isso permite o desenvolvimento de estratégias de controle mais adaptáveis e robustas, com potencial para melhorar o desempenho em uma ampla gama de aplicações, desde automação industrial até veículos autônomos e sistemas de controle de processos complexos.

2.3.1. Neurônio biológico

O processamento de informações no cérebro humano é governado por elementos processadores biológicos que operam em paralelo. A unidade fundamental do sistema nervoso cerebral é o neurônio, cuja função principal consiste na condução de impulsos, ou seja, estímulos elétricos. O neurônio é composto por três componentes principais: dendritos, responsáveis por receber estímulos de outros neurônios ou do ambiente externo; o corpo celular, encarregado de processar todas as informações provenientes dos dendritos, a fim de gerar um potencial de ativação que determina se o neurônio emitirá um impulso elétrico ao longo de seu axônio, conforme a Figura 4 (GOMIDE, 2012).


Figura 4 – Neurônio biológico



Fonte: SILVA; SPATTI; FLAUZINO (2010)

Os neurônios biológicos são responsáveis por todo o processamento executado e gerenciado pelo cérebro humano. Essas células nervosas são os blocos de construção do sistema nervoso e atuam na comunicação, transmissão de informações e coordenação das funções cerebrais. No entanto, é importante destacar que não há contato físico direto entre eles. A comunicação entre neurônios ocorre por meio de estruturas chamadas sinapses, imersas em substâncias neurotransmissoras, que permitem a transferência de informações de um neurônio para outro, conforme ilustra a Figura 5.

Figuras 5: Interconexão de neurônios: (a) substâncias neurotransmissoras; (b) neurônios biológicos interconectados




Fonte: (a) SILVA; SPATTI; FLAUZINO (2010); (b) freepik.com

As substâncias neurotransmissoras são responsáveis por ponderar a transmissão de impulsos elétricos entre os neurônios. Essas substâncias químicas, liberadas em resposta a estímulos elétricos, atuam na modulação da intensidade e na direção da transmissão de sinais nervosos.

2.3.2. Neurônio artificial

No contexto do modelo biológico, as influências transmitidas pelas conexões sinápticas são representadas no neurônio artificial por meio de um conjunto de pesos sinápticos (denominados $w_1, w_2 \dots w_n$). De maneira análoga, a importância de cada entrada individual (x_j) para o neurônio é determinada multiplicando-a pelo peso sináptico correspondente. Isso significa que todas as informações vindas de fora e recebidas pelo neurônio são consideradas, sendo a saída do neurônio artificial o resultado dessas ponderações das entradas, conforme a Figura 6 (GOMIDE, 2012).

Figura 6 - Neurônio artificial.



Fonte: SILVA; SPATTI; FLAUZINO (2010)

Um neurônio artificial é comumente representado matematicamente por meio de uma equação que descreve como ele combina suas entradas, aplica pesos a elas e, em seguida, passa o resultado por uma função de ativação. A equação matemática para um neurônio artificial é geralmente expressa da seguinte forma (SILVA; SPATTI; FLAUZINO, 2010).

$$u = \sum_{i=1}^n w_i \cdot x_i - \theta \quad (2)$$

onde:

i é o número de entradas do neurônio;

w_i é o peso associado com a i -ésima entrada;

θ é o limiar de ativação associado ao neurônio;

x_i é a i -ésima entrada do neurônio;

u é a saída do neurônio.

A saída do neurônio pode ser calculada pela equação (3):

$$y = g(.) = g(u) \quad (3)$$

onde:

$g(.)$ é a função de ativação do neurônio.

A função de ativação $g(\cdot)$, é geralmente uma função não linear que introduz não linearidades no processo. Exemplos comuns de funções de ativação incluem a função sigmoide, a função tangente hiperbólica, a função degrau e a função linear. A escolha da função de ativação depende da tarefa e da arquitetura da rede neural.

O funcionamento de um neurônio artificial em redes neurais pode ser resumido em algumas etapas fundamentais. Primeiro, o neurônio artificial recebe um conjunto de valores, que representam as variáveis de entrada. Cada entrada é então multiplicada pelo seu peso sináptico correspondente, e essas multiplicações são somadas para obter o potencial de ativação (u) do neurônio. Esse potencial de ativação é uma combinação linear das entradas ponderadas pelos pesos, o que permite ao neurônio atribuir diferentes importâncias a cada entrada (HAYKIN, 2001).

Em seguida, o potencial de ativação é submetido a uma função de ativação apropriada. Essa função de ativação serve para limitar a saída do neurônio e introduzir não-linearidades no processo. Após a aplicação da função de ativação, o neurônio artificial produz uma saída que representa a resposta do neurônio às entradas e pesos

dados. Essa saída é então utilizada como entrada para neurônios subsequentes na rede neural ou pode ser a saída final da rede, dependendo da arquitetura da rede e da tarefa em questão (SILVA; SPATTI; FLAUZINO, 2010).

Em resumo, um neurônio artificial em redes neurais processa informações recebidas por meio de multiplicações ponderadas, calcula um potencial de ativação, aplica uma função não-linear de ativação e, finalmente, gera uma saída que é usada para realizar tarefas de processamento de dados, aprendizado, ou tomada de decisões (GOMIDE, 2012).

2.4. Modelagem matemática de sistemas térmicos

As equações diferenciais são fundamentais na teoria de controle, especialmente quando se trata de sistemas dinâmicos contínuos no tempo. Elas descrevem a relação entre as variáveis do sistema e como essas variáveis mudam com o tempo. Para sistemas lineares e invariantes no tempo (LTI), as equações diferenciais que descrevem o sistema podem ser representadas como equações diferenciais lineares de ordem n (OGATA, 2010).

Uma maneira inteligente de lidar com Equações Diferenciais Ordinárias (EDOs) de sistemas lineares é empregar a Transformada de Laplace. O conceito fundamental dessa transformada reside na substituição do operador diferencial d/dt ou d/dx por uma variável no domínio da frequência representada por 's'. Dessa forma, as equações diferenciais são convertidas em equações algébricas (Fischer Abati, 2020).

Os sistemas térmicos são sistemas físicos que envolvem transferência e conversão de energia térmica, e eles operam com base no princípio fundamental da lei da conservação de energia, também conhecido como o primeiro princípio da termodinâmica. Este princípio estabelece que a energia total de um sistema isolado permanece constante, ou seja, a energia não pode ser criada nem destruída, apenas transformada de uma forma para outra.

Em sistemas térmicos, a lei da conservação de energia é aplicada especificamente à energia térmica. Isso implica que a soma das energias térmicas internas do sistema, as trocas de calor com o ambiente e o trabalho realizado (ou

recebido) no sistema devem ser iguais. Em termos matemáticos, a lei da conservação de energia para sistemas térmicos pode ser expressa como:

$$C \cdot \frac{dT}{dt} = \sum q_{ent} - \sum q_{sai} \quad (4)$$


em que: q é a taxa de fluxo de calor, dT é a derivada da temperatura no tempo e C é a capacitância térmica. A resistência térmica (R_T) é a variação de temperatura pela variação na taxa de fluxo de calor:

$$R_T = \frac{T_s - T_e}{q_{sai}} \quad (5)$$

Para os casos em que não há vapor ou temperatura de entrada, conforme ilustra a Figura 7, considera-se que $T_e = 0$, e assim obtém-se:

$$R_T = \frac{T_s}{q_{sai}} \rightarrow q_{sai} = \frac{T_s}{R_T} \quad (6)$$

Figura 7 – modelagem sistema térmico



Fonte: Ogata, Katsuhiko, 2010

Aplicando os conceitos do princípio fundamental da lei da conservação de energia, tem-se:

$$C \cdot \frac{dT}{dt} = q_{ent} - q_{sai} \quad (7)$$

Substituindo a equação (6) em (7):

$$C \cdot \frac{dT_s}{dt} = q_{ent} - \frac{T_s}{R_T} \quad (8)$$

Simplificando:

$$R_T \cdot C \cdot \frac{dT_s}{dt} + T_s = R_T \cdot q_{ent} \quad (9)$$

Rearranjando o sistema, obtém-se:

$$T_s \cdot (R_T \cdot C \cdot s + 1) = R_T \cdot Q_{ent} \quad (10)$$

Assim, a função de transferência que representa o sistema térmico da Figura 7, pode ser obtido:

$$FT = \frac{T_s}{Q_{ent}} = \frac{R_T}{R_T \cdot C \cdot s + 1} \quad (11)$$

A modelagem matemática de sistemas térmicos é empregada em diversas áreas da engenharia, ciência e tecnologia devido à sua importância para o entendimento, projeto, otimização e controle de sistemas que envolvem a transferência de energia térmica.

3 METODOLOGIA


Neste trabalho foram conduzidos experimentos em uma planta didática de temperatura com o objetivo de avaliar métodos de sintonia de controladores. Os experimentos ocorreram em duas etapas, conforme ilustra a Figura 8. Na etapa 1, um protótipo foi utilizado para validar os métodos de controle, e um *script* de validação foi desenvolvido para compará-los. A função de transferência do protótipo foi determinada por meio de experimentos de aplicação de um degrau de tensão. A planta experimental foi configurada para coletar dados de temperatura, com dois conversores desempenhando funções específicas no sistema.

Em seguida, a função de transferência da planta foi identificada por meio de experimentos semelhantes aos do protótipo, mas com considerações específicas para

a água como meio de aquecimento. Após a determinação da função de transferência, o controle PI foi sintonizado com sucesso utilizando o método de Dorf e Bishop.

Na etapa 2, os procedimentos se repetiram, no entanto, aplicados a uma planta didática Smar PD3-P. A planta didática Smar PD3-P é um equipamento utilizado em treinamentos e cursos relacionados a automação industrial e engenharia. Ela é produzida pela empresa Smar, uma renomada fabricante de instrumentação e automação industrial. A PD3-P é um sistema projetado para fornecer uma plataforma de ensino prática, na qual os estudantes e profissionais possam aprender sobre diversos conceitos e técnicas relacionados à automação industrial e ao controle de processos.

Figura 8 – Etapas da metodologia



Fonte: Autoria Própria (2023)

A seguir, será detalhado os procedimentos metodológicos utilizados nesse trabalho.


3.1. Método de identificação utilizado

O método de identificação aplicado no sistema foi o de Broída, que traça a resposta do sistema de primeira ordem a curva superior, verificasse que a um intervalo em comum entre elas definidos em intervalos de tempo de 28 e 40% de K, o qual se define pelo intervalo de início da curva até seu limite máximo. O delta Y, os intervalos de T e L, são calculados pelas fórmulas demonstradas na Figura 9.

O método de Broida é amplamente utilizado para otimizar o desempenho de sistemas de controle. Ele se baseia em algoritmos de otimização que buscam ajustar os parâmetros do controlador de forma a atender aos requisitos de desempenho desejados. Esse método permite aprimorar a estabilidade, a resposta transitória e a rejeição de distúrbios em sistemas de controle, garantindo que o sistema atenda

eficazmente às demandas do processo controlado. Ao iterativamente ajustar os parâmetros do controlador e avaliar o impacto dessas mudanças no sistema, o método de Broida contribui para a melhoria contínua da eficácia dos controladores em uma variedade de aplicações industriais e de engenharia.

Figura 9 – Método de Broida

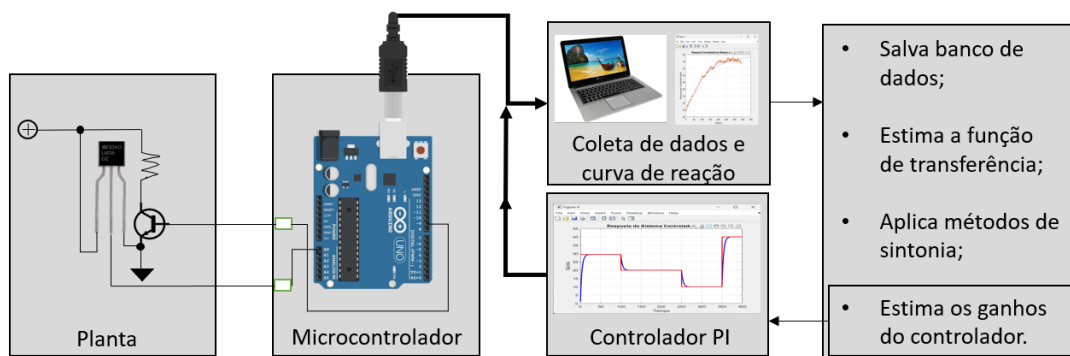


Fonte: Autoria Própria (2023)

3.2. Implementação de controle em protótipo de testes

Inicialmente, foram conduzidos testes em um protótipo como parte do processo de validação dos métodos de sintonia. Além disso, durante esse estágio, foi elaborado um script de validação dos métodos. Isso permitiu uma avaliação comparativa dos diferentes métodos de sintonia, a fim de identificar o mais eficaz. Essa abordagem foi adotada devido ao fácil manuseio e disponibilidade de deslocamento do protótipo, juntamente com a disponibilidade de acesso e flexibilidade de horários para o treinamento da rede neural.

Figura 10 – Fluxograma de implementação no protótipo

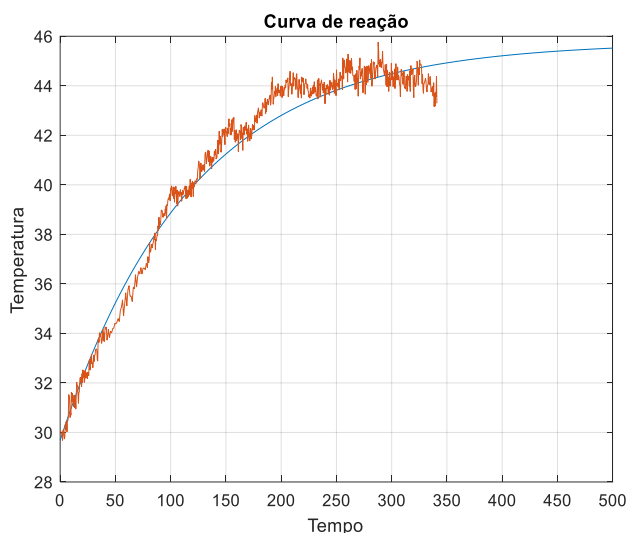


Fonte: Autoria própria (2023)

3.2.1. Determinação da Função de Transferência do protótipo

Com o propósito de identificar a função de transferência do protótipo foram conduzidos experimentos que consistiram na aplicação de um degrau de tensão conhecido por meio de um microcontrolador Atmel 328P da plataforma Arduino. Esse degrau de tensão foi aplicado para determinar a resposta da planta em malha aberta, incluindo sua curva de reação até atingir o regime permanente. Os dados resultantes dessas experimentações foram então submetidos a análises utilizando técnicas de avaliação de sistemas lineares. Esse procedimento possibilitou a dedução das relações matemáticas que descrevem o comportamento da planta em relação às variações nas entradas, conforme observa-se na Figura 11.

Figura 11 – Curva de reação do protótipo



Função de transferência

$$\frac{2.277}{118.1s + 1}$$

Protótipo

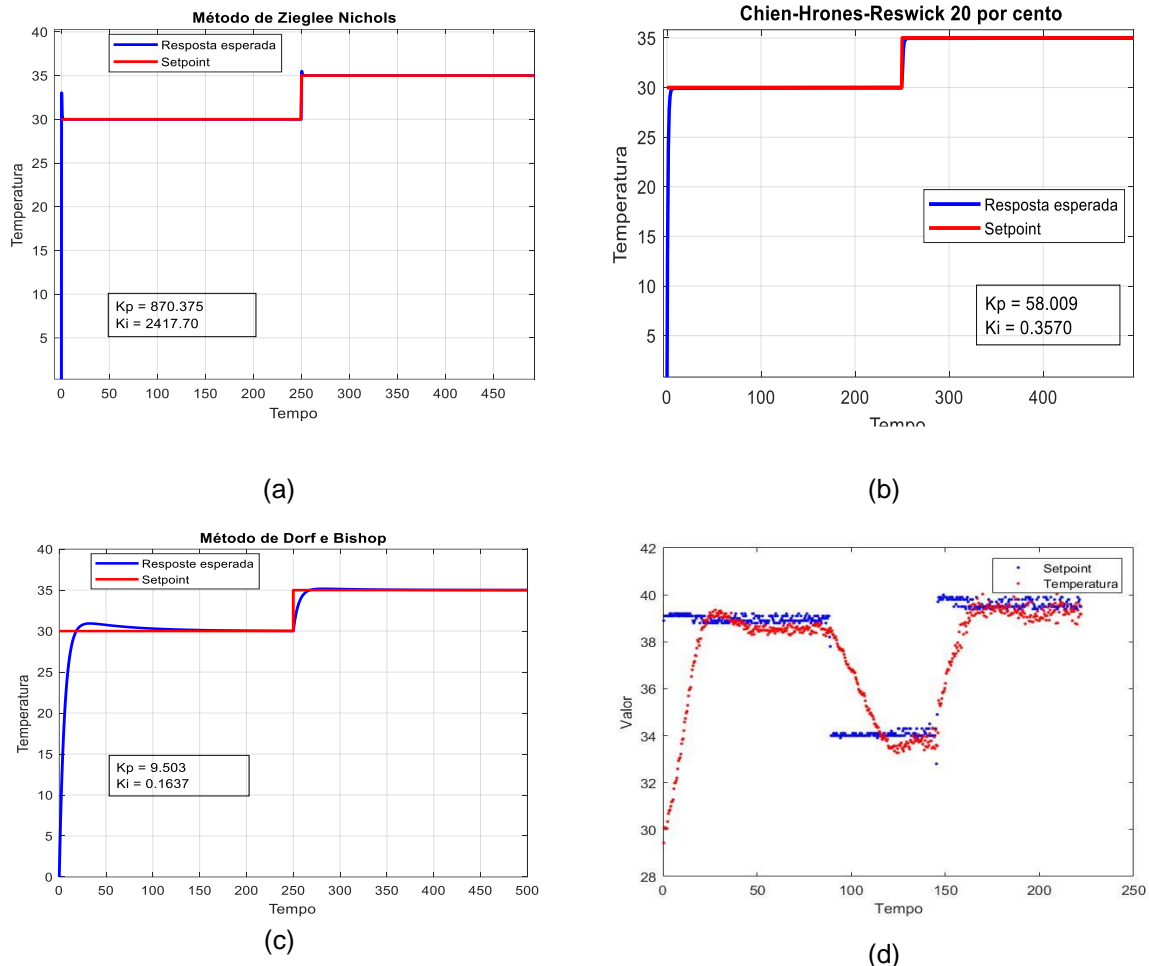
Fonte: autoria própria (2023)

3.2.2. Método de sintonia utilizado para o controle PI, Chien-Hrones-Reswick 20%

Ao escolher o método de teste ideal para o protótipo, realizou-se uma análise comparativa dos gráficos obtidos por meio do *script* de validação. A análise destacou o método de Chien-Hrones-Reswick com uma margem de 20% (Figura 12(b)), como a escolha mais eficaz e apropriada para o protótipo de teste real. Durante a avaliação dos métodos alternativos, observou-se que o método de Ziegler Nichols (Figura 12(a)), apresentou um *overshoot* inicial de 3 graus no início do degrau e de 1 grau após a

variação do *setpoint*. Além disso, a variável de temperatura demonstrou um atraso de inércia, persistindo na subida após o desligamento antes de se estabilizar.

Figura 12 – Aplicação de métodos de sintonia: (a) Método de Ziegler Nichols; (b) Chien-Hrones-Reswick 20%; (c) Método de Dorf e Bishop; (d) Chien-Hrones-Reswick.



Fonte: autoria própria (2023)

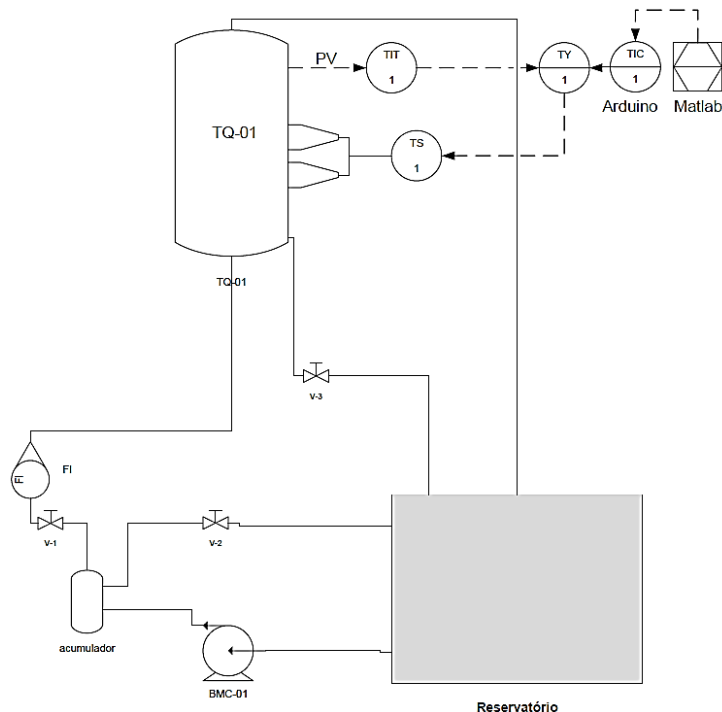
O método de Dorf e Bishop (Figura 12(c)) também revelou um *overshoot* inicial de 0,7 graus, que durou por um período de 100 segundos até a estabilização, com inércia residual na temperatura após o desligamento. A escolha do método de Chien-Hrones-Reswick 20% se fundamentaram na análise detalhada de sua resposta transitória satisfatória, evidenciada pela Figura 12(b). Este método se mostrou altamente eficaz em ambos os degraus, tanto o de partida quanto o de alteração, validando sua aplicação no nosso protótipo de teste real ilustrada na Figura 12(d).

3.3. Implementação de controle em Planta Didática Smar PD3-P

A planta didática Smar PD3-P é uma plataforma de ensino para cursos de automação industrial e engenharia, fabricada pela renomada empresa Smar. Com uma variedade de sensores, instrumentos, atuadores e controladores, a PD3-P oferece aos estudantes a oportunidade de aprender de forma prática os princípios fundamentais da automação e do controle de processos industriais. Essa planta didática oferece práticas envolvidas no controle de processos industriais, preparando-os para lidar eficazmente com desafios do mundo real na indústria.

A planta Smar PD3-P foi concebida e configurada para estabelecer um ambiente controlado, no qual as análises pudessem ser conduzidas de forma precisa e replicável. Essa configuração permitiu a coleta de dados relacionados à temperatura e ao processo de aquecimento, possibilitando a realização de estudos detalhados e a repetição das experiências de forma consistente. A Figura 13 ilustra o diagrama de tubulações e instrumentação (também conhecida como P&ID, do termo em inglês *Piping and Instrumentation Diagram*) utilizada nesse trabalho.

Figura 13 – Diagrama P&ID da planta Didática Smar PD3-P



BMC – bomba trifásica X cv.

FI – Indicador de vazão (rotâmetro).

TIT – Transmissor Indicador de Temperatura.

TY – Reles de conversão mA/V e V/mA.


TIC – Controlador de temperatura (Arduino)

TS – Banco de resistência (X W)

Fonte: autoria própria (2023)

As características específicas da SMAR PD3-P podem variar dependendo do modelo exato, mas geralmente incluem um tanque ou processo de controle, instrumentação, controladores, interface de usuário, software de supervisão e documentação. Ela é uma ferramenta valiosa para treinar e educar engenheiros, técnicos e estudantes nas áreas de automação industrial e controle de processos, permitindo a exploração de conceitos práticos em um ambiente controlado e seguro. Suas características podem ser personalizadas com base nas necessidades específicas de treinamento e aprendizado e estão apresentadas na Figura 14.

Figura 14– Planta didática Smar PD3-P



Fonte: autoria Própria (2023)


3.3.1 Configuração dos conversores

Para a realização deste estudo, foi implementado um sistema experimental composto por dois conversores. O primeiro conversor, do tipo corrente para tensão, foi empregado para coletar dados de temperatura por meio de um transmissor com saída de corrente variando de 4 a 20 mA. A saída deste transmissor foi convertida em um sinal de tensão para permitir a leitura pelo microcontrolador Atmel 328p embarcado na plataforma Arduino.

O segundo conversor, do tipo tensão para corrente, desempenhou um papel crucial no sistema, transformando a saída de tensão em um sinal PWM (*Pulse Width*

Modulation), o qual variava de acordo com as exigências do processo. Este sinal PWM de 4 a 20 mA foi então utilizado para controlar o banco de tiristores, que, por sua vez, regulava a potência fornecida às resistências de aquecimento. Dessa forma, o processo de aquecimento das resistências era controlado de acordo com o sinal de tensão gerado pelo conversor. A Figura 15 ilustra a conexão dos conversores.

Figura 15 – Fluxograma de ligação dos conversores



Fonte: autoria própria (2023)


3.3.2. Determinação da Função de Transferência da Planta Smar PD3-P

Com o propósito de identificar a função de transferência da planta, foram conduzidos experimentos que consistiram na aplicação de um degrau de tensão por meio de um microcontrolador da plataforma Atmel. Esse degrau de tensão foi aplicado para determinar a resposta da planta em malha aberta, incluindo sua curva de reação até atingir o ponto de saturação.

No entanto, a planta didática utiliza água líquida como meio de aquecimento, o que implica que não existe um ponto de saturação definido, uma vez que a água entra em ebulição a 100°C. Diferente do resistor utilizado no protótipo, que possui um ponto de saturação bem definido. Porém os dados resultantes dessas experimentações foram então submetidos a análises utilizando técnicas de avaliação de sistemas lineares. Esse procedimento possibilitou a dedução das relações matemáticas que

descrevem o comportamento da planta em relação às variações nas entradas, conforme ilustra a Figura 16.

Figura 16 – Curva de reação da planta Smar PD3-P




Fonte: autoria Própria (2023)

3.3.3. Método de sintonia utilizado para o controle PI, Dorf e Bishop

Para a escolha do método de sintonia ideal para a planta, realizou-se uma análise comparativa entre alguns métodos clássicos de sintonia. Conforme evidenciado na Figura 17(a), o método de Ziegler Nichols apresentou um *overshoot* de 1,15 graus e um tempo de acomodação de 35 segundos após o tempo de subida. Após uma alteração de 5 graus no setpoint, o *overshoot* diminuiu para 0,15 graus. No entanto, devido à inércia da temperatura nas condições reais, o *overshoot* foi considerado significativamente maior.

Por outro lado, na Figura 17(b), que representa o método de Método de Dorf e Bishop, demonstrou a ausência de *overshoot*, juntamente com um tempo de acomodação de 35 segundos. Isso valida o método como a escolha mais apropriada para o controle, uma vez que a defasagem de tempo resulta em um atraso praticamente nulo na temperatura após o desligamento. Em contrapartida, Chien-Hrones-Reswick 20%, também não apresentou *overshoot*, porém o tempo necessário para a estabilização foram substancialmente maiores, em torno de 250 segundos, tanto no início do *setpoint* quanto durante o deslocamento do *setpoint*. Essa demora excessiva na estabilização invalidou a aplicação desse método.

Figura 17 – Aplicação de métodos de sintonia: (a) Método de Ziegler Nichols; (b) Chien-Hrones-Reswick; (c) Método de Dorf e Bishop.



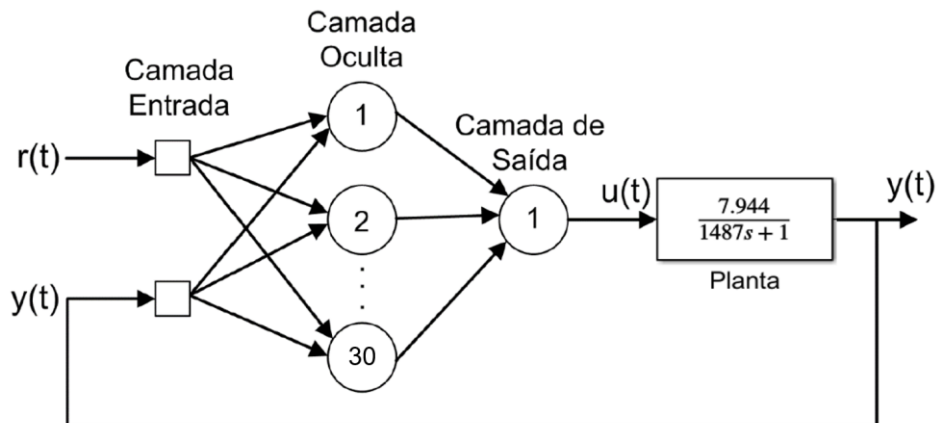
Fonte: autoria própria (2023)

Assim, pelos dados apresentados, optou-se pela escolha do método de sintonia de Dorf e Bishop, com K_p de 32,479 e K_i de 0,0459. O controle foi implementado experimentalmente na planta didática, e os resultados serão discutidos na Seção 4.

3.3.4. Método de controle utilizando um controlador PI-Neural

A rede proposta é composta por três camadas: a camada de entrada, na qual são fornecidos os valores de referência e velocidade real; a camada intermediária, que contém cinco neurônios; e a camada de saída, onde a ação de controle é aplicada. A arquitetura do controlador PI-Neural é adaptada da pesquisa de Junior; Vargas; Goedel (2013) representada na Figura 18.

Figura 18 – Arquitetura do controlador Pi-Neural



Fonte: autoria Própria (2023)

onde:

$r(t)$ é a referência de temperatura;

$u(t)$ é a ação de controle;

$y(t)$ é o valor real de temperatura.

No desenvolvimento deste trabalho, foi empregado um método de treinamento supervisionado utilizando o software MatLab (versão R2020a) em um computador com processador Intel(R) Core (TM) i5-10500H CPU @ 2.50GHz, 2496 Mhz, 6 Núcleo(s), 12 Processador(es) Lógico(s) e Sistema Operacional Microsoft Windows 11 Pro. Durante o treinamento, foram fornecidos dados de entrada e saída que descrevem de maneira satisfatória o comportamento do sistema, permitindo a obtenção dos parâmetros internos ideais para a rede neural. As amostras de treinamento utilizadas foram provenientes de um controlador PI convencional com os parâmetros de sintonia obtidos no método de Dorf e Bishop, com K_p de 32,479 e K_i de 0,0459. Os parâmetros da rede neural proposta estão apresentados na Tabela 2.

Tabela 2 – Parâmetros da rede neural artificial

Arquitetura da rede	<i>Perceptron</i> multicamadas
Tipo de treinamento	Supervisionado
Número de camadas	2
Neurônios na camada escondida	30
Algoritmo de treinamento	<i>Backpropagation</i>
Taxa de aprendizagem	0.1

Épocas	5000
Erro quadrático requerido	1e-8
Ativação camadas intermediárias	Função Logística
Ativação da camada de saída	Função Logística
Amostras para treinamento	4728 amostras
Amostras para validação	1800 amostras

Fonte: Autoria própria (2023).

Para a validação, implementada experimentalmente na planta Smar, foi proposto um método para autoajuste dos pesos, que ocorre em tempo real por meio da multiplicação entre uma taxa de aprendizagem e o erro. Esse escalar é multiplicado a matriz de pesos.

4 APRESENTAÇÃO E DISCUSSÃO DOS RESULTADOS

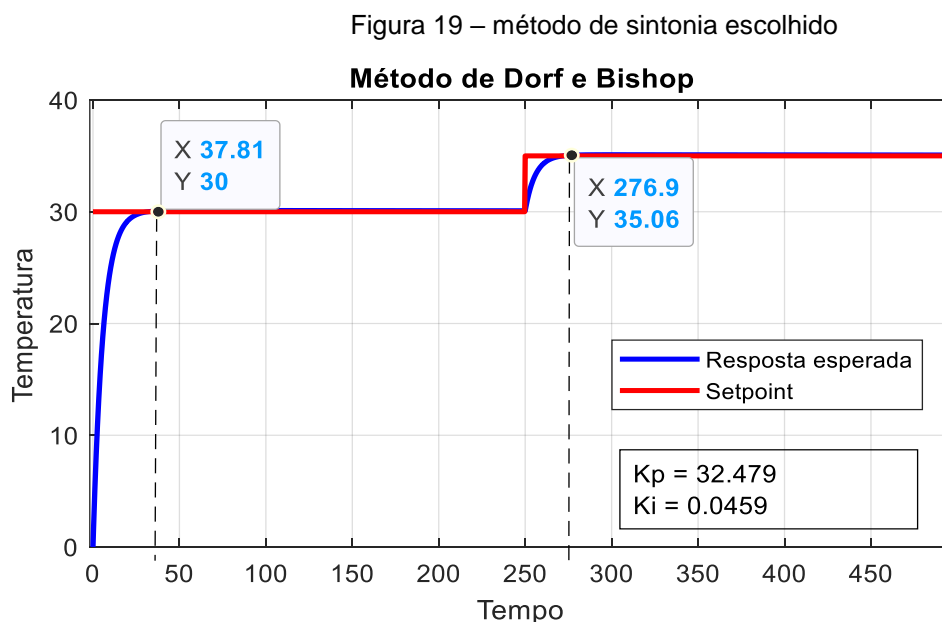
A metodologia abordada neste trabalho permitiu uma análise sistemática da planta didática de temperatura e a sintonia eficaz do controlador PI. Os resultados obtidos demonstraram a eficiência da sintonia pelo método de Dorf e Bishop na obtenção de um controle preciso da temperatura. Além disso, enfatizou-se a importância da configuração da planta e da determinação da função de transferência como passos preliminares cruciais para a sintonia bem-sucedida do controlador.

Após a sintonia do controlador, foram realizados ensaios experimentais no sistema, incluindo um teste de degrau, no qual a temperatura de referência foi abruptamente alterada. Os dados resultantes foram registrados e analisados graficamente para avaliar o desempenho do controlador PI. A análise incluiu a verificação da resposta do sistema, a estabilidade e a capacidade de seguir a temperatura de referência.

4.1. Sintonia do Controlador PI:

A etapa crítica deste estudo envolveu a sintonia do controlador PI, que se iniciou com a identificação dos parâmetros iniciais. Posteriormente, foi desenvolvido um *script* em software computacional específico para a sintonia utilizando o método

de Dorf e Bishop. Esse método incluiu a análise e otimização dos ganhos do controlador para alcançar os objetivos desejados de desempenho, como rápida convergência e mínima oscilação. Os resultados indicam a ausência de *overshoot* e um tempo médio de acomodação de 37 segundos, tanto no início do *setpoint* quanto na mudança do degrau, como ilustrado na Figura 19.




Após estabelecer que o método de de Dorf e Bishop apresenta o melhor resultado entre as sintonias de controladores os valores dos ganhos do controlador são armazenados, para serem aplicados experimentalmente na planta didática Smar PD3-P.

4.2. Resultados obtidos através de simulação feita na planta didática Smar PD3-P com PI Clássico

No primeiro teste realizado na planta Smar com os ganhos obtidos, se obteve resultados significativos. Ao iniciar o ensaio experimental, não se observou *overshoot*, indicando uma resposta inicial controlada. No entanto, a temperatura não se estabilizou exatamente sobre o *setpoint* desejado. Após o deslocamento do degrau, houve um *overshoot* de 0,5 graus, que perdurou por um tempo de acomodação de 1820 segundos, equivalente a cerca de 30 minutos.

Esse *overshoot* foi uma observação importante nos resultados, e sua ocorrência foi atribuída à inércia térmica do tanque. A inércia térmica do tanque resulta em um atraso na resposta à mudança de temperatura, o que significa que a temperatura não atinge imediatamente o *setpoint*. Isso levou ao *overshoot*, onde a temperatura ultrapassou temporariamente o valor desejado antes de se estabilizar conforme ilustra a Figura 20. Esses resultados ressaltam a importância de ajustar os ganhos do controlador para minimizar o *overshoot* e alcançar um controle mais preciso da temperatura.

Figura 20 – método de sintonia PI aplicado a planta Smar PD3-P



Fonte: autoria Própria (2023)

No segundo ensaio experimental, foi alcançada uma estabilização melhor, sem a ocorrência de *overshoot*, e o tempo de subida foi de 500 segundos, o que equivale a 8,3 minutos, como ilustrado na Figura 21. Além disso, observou-se que o tempo de subida permaneceu inalterado em relação à simulação anterior apresentada na Figura 20. Outra observação relevante foi que o *overshoot* ocorre quando o aumento do *setpoint* ultrapasse 2,5 graus Celsius, conforme evidenciado na Figura 22.

Na referida figura, apresenta-se três ensaios sobrepostos no gráfico, para a visualização da resposta do sobressinal e do tempo de acomodação, conforme altera-se o valor de referência. No quarto teste, o *overshoot* foi de 0,48 graus Celsius com um tempo de 17,98 minutos.

Figura 21 – Controle PI obtido pelo Método Dorf e Bishop (teste 2)


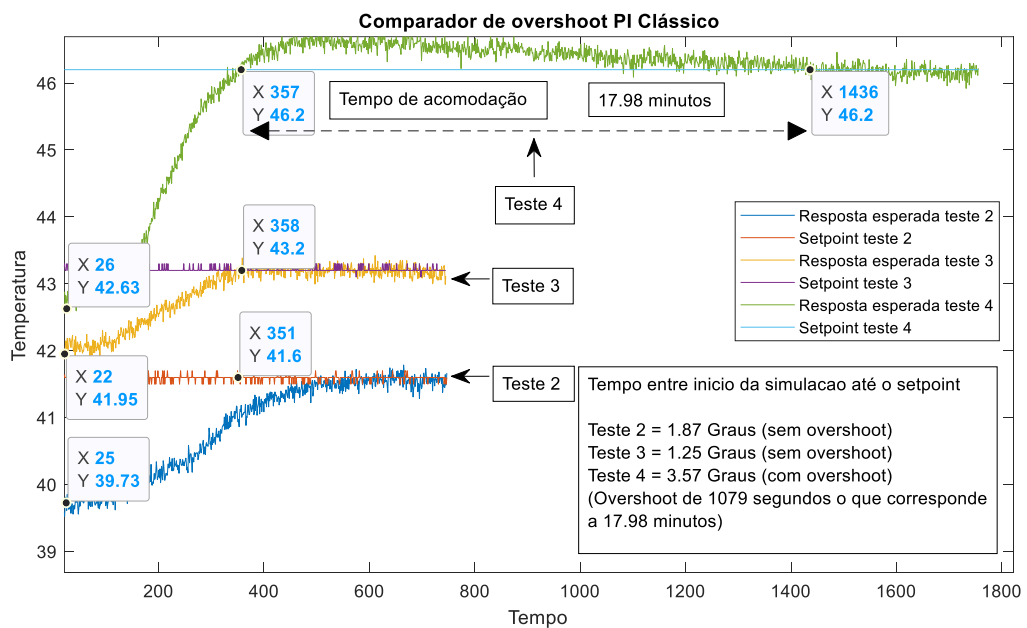


Figura 22 – Comparação do overshoot no controle PI




4.3. PI Neural

A melhor resposta do controle PI obtida experimentalmente pelo método de Dorf e Bishop foi utilizada para o treinamento do controlador PI-Neural. Assim, foram coletados e salvos os sinais de *setpoint*, temperatura e *duty cycle*. No modelo da rede neural proposto na Seção 3.3.4, o sinal de *setpoint* refere-se a “ $r(t)$ - referência de temperatura”, o sinal de temperatura refere-se a “ $y(t)$ - valor real de temperatura” e o *duty cycle* refere-se a “ $u(t)$ - ação de controle”.

O *duty cycle* (ciclo de trabalho) em um PWM (*Pulse Width Modulation*, ou Modulação por Largura de Pulso, em português) refere-se à proporção do tempo em que o sinal PWM está em nível alto em relação ao período completo do sinal. Essa variação de PWM é utilizada para o controle dos tiristores responsáveis pelo aquecimento do reservatório.

A Figura 23 ilustra o sinal de *duty cycle* utilizado para o treinamento da rede neural. O referido sinal amostrado foi submetido a uma ferramenta de filtragem (FitCurve – Matlab) para linearização e eliminação de parte dos ruídos.

Figura 23 – Duty de treinamento



Fonte: autoria Própria (2023)

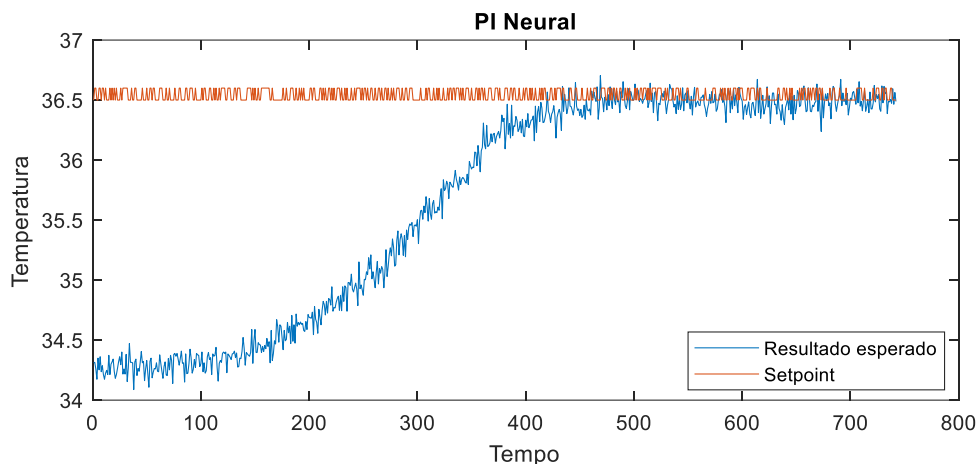
A partir das 4728 amostras de treinamento, obteve-se a melhor configuração da rede neural capaz de aproximar o sinal de controle PWM a partir das entradas de referência e temperatura real. Esse método permite o controle do sistema sem a necessidade do modelo matemático do sistema. A validação ocorreu com 1800 dados que não foram utilizadas no treinamento. Após a etapa de validação computacional, obteve-se as matrizes de pesos $W1$ e $W2$ otimizadas para o controlador PI-Neural.

Adicionalmente, o sistema de controle PI-Neural proposto implementa um ajuste de pesos adaptativo, conforme há erro entre a referência e a temperatura real. Isso ocorre a cada iteração do controle, em que o erro é multiplicado por uma taxa de aprendizagem (n) e somado a matriz de pesos da iteração anterior. Assim, sempre que houver erro haverá adaptação dos pesos. Esse fato pode contribuir para a melhoria da convergência do controle em regime transitório e permanente.

4.4. Resultados obtidos através de simulação feita na planta didática Smar PD3-P com PI Neural

A resposta do controle PI Neural pode ser observada na Figura 24. O *setpoint* foi ajustado para 36,54 graus e observa-se uma melhoria no tempo de subida em comparação ao controle PI Clássico. A temperatura permaneceu estável com poucas variações.


Figura 24 – Controle PI Neural obtido (teste 1)



Fonte: autoria Própria (2023)

A Figura 25 ilustra uma análise comparativa entre a melhor resposta do controlador PI clássico com o controlador PI-Neural. Observa-se, que em ambos os métodos não houve a ocorrência de *overshoot*. O tempo de melhora na resposta foi de 113 segundos.


Figura 25– Comparação PI Clássico x PI Neural



Fonte: autoria Própria (2023)

Além disso, como evidenciado na Figura 26, notou-se que, independentemente do valor de alteração do *setpoint*, o controle PI-Neural não apresenta *overshoot*, o que é uma diferença marcante em relação ao PI Clássico, onde *overshoot* já era observado após uma alteração de 2,5 graus no *setpoint*.

Figura 26 – Comparação de overshoot no controle PI Neural

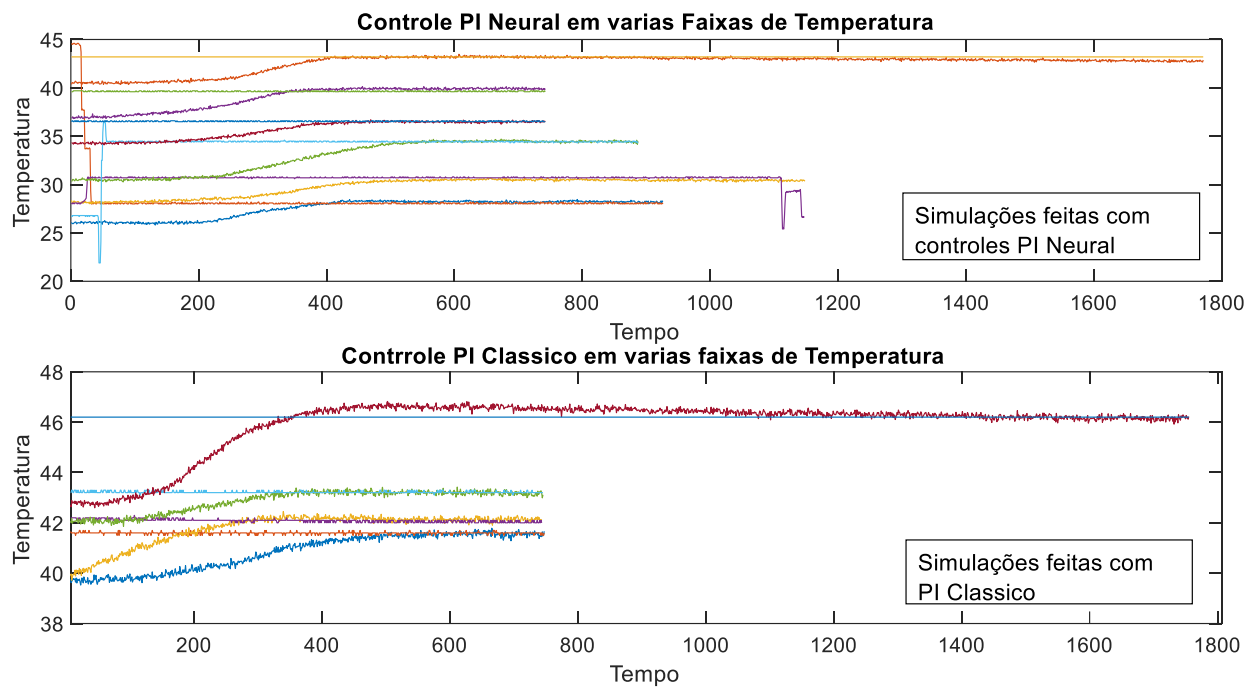


Fonte: autoria Própria (2023)

Uma melhoria substancial adicional, conforme destacado na Figura 27, foi a consistência das simulações do controle PI Neural. Independentemente da distância entre a temperatura atual e a temperatura desejada, nenhuma das simulações apresentou *overshoot*. Isso demonstra de maneira excepcional a eficácia do treinamento dos pesos aplicados à rede neural, validando sua performance de forma sólida e consistente.

Esses resultados indicam que o uso de redes neurais artificiais como método de controle pode ser altamente eficaz na melhoria do desempenho de sistemas de controle, resultando em respostas mais rápidas e uma maior linearidade, o que pode ser fundamental em diversas aplicações práticas. Portanto, os benefícios observados nesse estudo destacam o potencial das redes neurais artificiais como uma ferramenta valiosa no campo do controle de sistemas.

Figura 27 – Todos os testes PI (Clássico e Neural) executados



Fonte: autoria Própria (2023)

Na Figura 27 evidencia-se que o controle PI-Neural pode ser utilizado para uma ampla faixa de valores de referência promovendo uma estabilização aceitável, com melhorias significativas, se comparada ao controle PI convencional.

5 CONSIDERAÇÕES FINAIS

O presente trabalho apresenta um estudo comparativo entre o controlador PI convencional e o controlador PI-Neural aplicado ao controle de sistemas térmicos, com o objetivo de controlar suavemente sua temperatura. O sistema proposto baseou-se em dados gerados em um processo que foi sintonizado por métodos convencionais. A aplicação de um degrau de tensão aos tiristores que controlam um banco de resistências produz uma sequência de dados relativos ao processo. A sintonia de controladores do tipo PI apresentaram bons resultados, validando os métodos propostos na literatura. Com base nos dados de um controle clássico foi proposto um controlador PI-Neural com ajuste de pesos.

Através do método de treinamento, houve o ajuste dos pesos sinápticos dos neurônios da rede com o objetivo de otimizar a resposta do controle. O controlador PI-Neural demonstrou maior eficiência se comparado ao controlador PI identificado e sintonizado por métodos convencionais.

A implementação do controle de rede neural artificial resultou em melhorias significativas na resposta do sistema. Foi observada uma otimização dos dados, com uma redução de aproximadamente 15% no tempo de estabilidade. Além disso, foi evidente uma notável melhoria na linearidade do sistema em comparação com o controle proporcional-integral (PI).

Cabe ainda ressaltar os resultados satisfatórios, não apresentando máximos sobressinal, demonstrando menor tempo de subida após a aplicação de distúrbio, menor tempo de assentamento e menor erro estacionário. Isso demonstrou que sistemas inteligentes baseados em redes neurais são uma alternativa para sistemas de controle para os quais não é possível obter a função de transferência que descreve precisamente o comportamento do sistema.

REFERÊNCIAS

- CAMPOS, M. C. M. M. DE; TEIXEIRA, H. C. G. **Controles típicos de equipamentos e processos industriais.** [s.l.] Editora Blucher, 2010.
- FACCIN, F. Abordagem inovadora no projeto de controladores PID. 2004.
- FERREIRA, M. H.; DE MOARES, M. A. REDES NEURAS ARTIFICIAIS: PRINCÍPIOS BÁSICOS. v. 1, n. 13, 2016.
- FISCHER ABATI, G. **SIMULAÇÃO E VALIDAÇÃO EXPERIMENTAL DE CONTROLE PID E LQR EM UM SISTEMA SUB-ATUADO COM PÊNDULO INVERTIDO.** ENGENHEIRO MECÂNICO—Rio de Janeiro, Brazil: PONTIFÍCIA UNIVERSIDADE CATÓLICA DO RIO DE JANEIRO, 2020.
- GARCIA, C. **Controle de processos industriais: estratégias convencionais.** [s.l.] Editora Blucher, 2021.
- GOMIDE, F. A. Redes neurais artificiais para engenharia e ciências aplicadas: curso prático. **Sba: Controle & Automação Sociedade Brasileira de Automatica**, v. 23, p. 649–652, out. 2012.
- HAYKIN, S. **Redes Neurais: Princípios e Prática.** [s.l.] Bookman Editora, 2001.
- JUNIOR, V. A. F; VARGAS, A. N.; GOEDEL, A. Uma Abordagem PI-Neural Aplicado ao Controle de um Servo-Mecanismo. Simpósio Brasileiro de Automação – SBAI, 2013.
- OLIVEIRA, R. M. DE. **Aplicação de controle PID não linear com ganhos baseados em perfil gaussiano aplicado a um conversor Buck.** masterThesis—[s.l.] Universidade Tecnológica Federal do Paraná, 29 ago. 2014.
- SARAIVA, 2011. MÉTODOS DE SINTONIA EM CONTROLADORES PID. [s.d.].
- SILVA, W. J. DA. APLICAÇÃO DE MALHA FECHADA EM UM SISTEMA DE FRENAGEM INDUSTRIAL TÊXTIL. 29 nov. 2021.
- SILVA, I. N.; SPATTI, D. H.; FLAUZINO, R. A. Redes Neurais Artificiais para engenharia e ciências aplicadas: curso prático. São Paulo: Artliber, 2010.
- YU, C.-C. **Autotuning of PID Controllers: Relay Feedback Approach.** [s.l.] Springer Science & Business Media, 2013.

Capítulo IV – Sintonia Adaptativa de Controladores PID Utilizando Redes Neurais

Edson da Silva Bueno ¹¹

Layhon Roberto Rodrigues dos Santos ¹²

Victor Emanuel Correia De La Rosa ¹³

Fabio Rodrigo Milanez ¹⁴

RESUMO

Este artigo apresenta um sistema de controle PID para o controle de fluidos em ambientes industriais, auxiliado por redes neurais, destacando a importância da estabilidade e do escoamento laminar para medições precisas em tanques pulmões. A abordagem PID adaptativa com redes neurais é comparada com métodos tradicionais de sintonia PID e aqueles baseados no enxame de partículas (PSO). O PID neural adaptativo regula a velocidade de bombeamento para manter o nível do fluido estável, mesmo em condições de vibração, turbulência e variações nas propriedades do fluido. Os métodos de sintonia considerados incluem abordagens empíricas, sensibilidade limite, PSO e autoajuste, sendo comparados ao PID com redes neurais por meio das métricas de IAE (Integral do Erro Absoluto), ITAE (Integral do Tempo do Erro Absoluto) e ISE (Integral do Erro ao Quadrado).

Palavras-chave: controle; PID adaptativo; rede neural artificial; otimização por enxame de partículas; tanques pulmões.

Adaptive Tuning of PID Controllers Using Neural Networks

ABSTRACT

This article presents a PID control system for fluid regulation in industrial environments, assisted by neural networks, highlighting the importance of stability and laminar flow for accurate measurements in surge tanks. The adaptive PID approach with neural networks is compared to traditional PID tuning methods and those based on particle swarm optimization (PSO). The adaptive neural PID controls the pumping speed to maintain a stable fluid level, even under conditions of vibration, turbulence, and variations in fluid properties. The tuning methods considered include empirical approaches, limit sensitivity, PSO, and self-tuning, which are compared to the PID with neural networks using the performance metrics of IAE (Integral of Absolute Error), ITAE (Integral of Time-weighted Absolute Error), and ISE (Integral of Squared Error).

Keywords: control; adaptive PID; artificial neural network; particle swarm optimization; surge tanks.

¹¹ Engenheiro Eletricista. UniSenaiPR - Campus Londrina.

¹² Doutor em Engenharia Elétrica.

¹³ Especialista. UniSenaiPR - Campus Londrina

¹⁴ Mestre em Bioenergia. UniSenaiPR - Campus Londrina.

1 INTRODUÇÃO

A medição de vazão de um fluido é um desafio comum em diversos processos industriais, especialmente aqueles onde a matéria-prima possui alto valor agregado e requer precisão na dosagem de ativos. A estabilidade e o escoamento laminar da vazão são fundamentais para garantir medições assertivas, entretanto diversos fatores como vibrações, turbulências, impurezas, bolhas, variações nas propriedades do fluido, mudanças na demanda e ruídos, podem impactar direta ou indiretamente as medidas. (Santos L.V.S,2014).

Em busca de soluções, é comum utilizar tanques pulmões, para armazenar temporariamente fluidos a fim de minimizar perturbações no processo. No entanto, essa abordagem apresenta limitações, uma vez que tanques maiores requerem mais espaço e geram custos elevados, enquanto tanques menores dificultam o controle e sincronização do sistema **(Souza et al, 2020, p. 52)**.

Em processos industriais por questões de eficiência, qualidade, economia além de segurança e normas, surge a necessidade de controlar variáveis como temperatura, vazão, nível, pressão entre outras sendo comumente utilizado o controle PID (Romão, 1996, pag.5).

O presente artigo visa enfrentar desafios como vibrações, turbulências, impurezas, bolhas, variações nas propriedades do fluido, mudanças na demanda e ruídos por meio de uma abordagem exploratória, centrada na comparação entre sintonizações PID convencionais e PID adaptativo. Sendo a escolha de uma bomba de transferência para avaliar o desempenho do controle de velocidade, mantendo o nível de um pulmão de pequeno porte estável, destaca a aplicabilidade prática dessa pesquisa.

O artigo propõe a utilização de um controlador PID adaptativo auxiliado por redes neurais artificiais e realiza comparações com métodos de sintonia PID que são consolidados na literatura, tais como os métodos de sintonia empírica, de sensibilidade limite, autoajuste do CLP SIMATIC STEP 7 1200 Siemens e de enxame de partículas. Estes métodos são comparados por meio de métricas como a integral erro absoluto no tempo (ITAE), a integral do erro absoluto (IAE) e a integral do quadrado do erro (ISE), as quais avaliam as condições de desempenho para

diferentes critérios de desempenho, por exemplo: o impacto do erro conforme aumenta o tempo de convergência, pode ser aferido pela métrica ITAE; o impacto do erro independente do tempo de convergência pode ser aferido pela métrica IAE; e o impacto dos erros que possuem maiores valores pela métrica ISE.

A proposta do PID adaptativo auxiliado por redes neurais, utiliza conceitos de redes neurais não apenas proporciona uma nova perspectiva sobre o controle de sistemas dinâmicos, mas também sugere a viabilidade de abordagens adaptativas. Destaca-se a importância da integração entre princípios consolidados e conceitos em aprendizado de máquina contemporâneo. Esta proposta não se limita a contribuições teóricas, mas almeja impactos práticos em ambientes industriais, fornecendo a estes ambientes um controle mais robusto e adaptável.

A proposta visa superar as limitações de métodos de controles de nível convencionais as quais enfrentam dificuldades ao lidar com interferências como vibrações, turbulências, impurezas e variações nas propriedades do fluido. Para alcançar esse objetivo, a abordagem proposta compara métodos diferentes de sintonia do controle PID encontrados na literatura em aplicações industriais convencionais.

Para tal utiliza-se o método empírico, onde é realizado de forma experimental, o método de sensibilidade limite, pelo fato de ser legitimado ao longo do tempo, o de enxame de partículas, pelo fato de ser uma método meta-heurístico e já introduzindo os conceitos de redes neurais aplicadas as métricas de desempenho ITAE, IAE e ISE para avaliar o desempenho dos controladores PID.

A integração entre princípios consolidados e conceitos em aprendizado de máquina é destacada ao longo do texto, estabelecendo uma comparação entre o controlador PID discreto e o *Perceptron* sendo o modelo mais simples de uma rede neural artificial proposto por Frank Rosenblatt em 1957. Essa investigação a priori se concentra na simplicidade do *Perceptron* não sendo foco redes neurais complexas, entretanto ressalta a convergência entre os domínios de controle clássico e aprendizado de máquina, além de sugerir a viabilidade de abordagens adaptativas que se beneficiam dessa síntese conceitual.

A alvo da proposta é proporcionar melhorias tangíveis no controle de sistemas dinâmicos, enfatizando a adaptabilidade dos controladores PID. A sintonia adaptativa

dos ganhos por meio da rede neural é apresentada como um elemento-chave que influencia a adaptação dos pesos do controlador PID, visando otimizar autonomamente o desempenho do sistema diante das variabilidades do processo.

Espera-se que a discussão e a análise comparativa dos métodos propostos gerem percepções valiosas, não apenas do ponto de vista teórico, mas também com aplicações práticas potenciais em ambientes industriais, resultando em sistemas de controle mais robustos e adaptáveis.

2 FUNDAMENTAÇÃO TEÓRICA

Nesta seção é discutido sobre os conceitos teóricos: na subseção 2.1, controlador PID tradicional e adaptativo, métodos de sintonia tradicionais, enxame de partículas e por meio de redes neurais; na seção 2.2, redes neurais.

2.1 Controlador PID

O controlador PID é capaz de controlar uma ampla variedade de processos, desde que seja sintonizado adequadamente. É um algoritmo simples e de baixo custo, o que o torna uma opção ideal para a maioria dos processos industriais, devido à sua simplicidade e robustez. (ÅSTRÖM e POULIN, 1996 apud Romão). Na seção 2.1.1 é apresentado controlador PID tradicional.

2.1.1 Controlador PID tradicional

De acordo com FERMINO (2014), O controlador PID é um algoritmo de controle que combina três ações: proporcional, integral e derivativa. A ação proporcional é a mais simples e atua diretamente sobre o erro, ou seja, a diferença entre o valor desejado e o valor atual do processo. A ação integral atua sobre a integral do erro, ou seja, a soma acumulada do erro ao longo do tempo. A ação derivativa atua sobre a derivada do erro, ou seja, a taxa de variação do erro.

A seguir, são apresentadas as ações do controlador PID segundo Souza (2013), onde a representação matemática no tempo contínuo, expressa na eq. 1, combina as ações proporcional (P), integral (I) e derivativo (D), características que

solidificaram o PID como um método de controle tradicionalmente reconhecido e amplamente adotado na indústria:

- **Proporcional:** fornece uma relação linear entre o sinal de entrada e a saída do controlador.
- **Integral:** ação integral que faz a saída do controlador aumentar numa taxa proporcional a integral da entrada do controlador.
- **Derivativo:** uma ação derivativa, ou seja, com base na tendência do erro, a ação derivativa se antecipa na ação de controle.

$$y(t) = Kp \left(e(t) + \frac{1}{T} \int_0^t e(t)dt + Td \frac{de(t)}{dt} \right) \quad (1)$$

Podem ser projetados com uma estrutura PID, controladores conhecidos como PID adaptativos, utilizando estimadores de parâmetros em tempo real para sintonização. Na subseção 2.1.2 é argumentado a necessidade de adaptação dos parâmetros Kp , Ki e Kd , do controlador PID.

2.1.2 Controlador PID Adaptativo

Segundo Romão (1996) em um sistema de controle adaptativo, é inevitável identificar constantemente as características dinâmicas do processo, permitindo o ajuste dos parâmetros do controlador, para manter o melhor desempenho.

O controle adaptativo é capaz de lidar com variações ambientais, o sistema adapta-se a erros moderados de engenharia e compensa falhas nos componentes, aumentando a confiabilidade global (Romão,1996).

Na literatura diversos algoritmos capazes de realizar o controle adaptativo no campo das disciplinas de Sistemas Lineares e Não-Lineares, de Teoria da Estabilidade, de Projeto de Controladores, de Controle Estocástico, de Sistemas Amostrados, de Identificação de Sistemas, de Estimação de Parâmetros, de Controle por Computador, de Inteligência Artificial, de Redes Neurais, de Controle Fuzzy, de Sistemas Especialistas e Otimização (Romão;1996).

A pesquisa em controle adaptativo se iniciou com estudos de automatizadas de alto desempenho, na década de 50. Já, na década de 1960 houve avanços com as teorias de espaço de estados e estabilidade, juntamente com desenvolvimentos em

controle estocástico, identificação de sistemas e estimação de parâmetros (Romão;1996).

Os controladores PID adaptativos superam os convencionais principalmente em sistemas complexos. Em tais casos, os controladores adaptativos oferecem robustez para ajustar-se a mudanças na dinâmica do processo (Romão;1996).

De acordo com Romão (1996) os procedimentos baseados na segunda geração buscam robustez em condições variáveis e simplificação nas especificações, podendo ser indireto e direto. No primeiro, o modelo do processo é parametrizado em termos dos parâmetros do controlador, enquanto no segundo, baseado na técnica autoajustável, o controle é calculado supondo parâmetros conhecidos do processo.

Tanto no procedimento direto como no indireto, utilizam estimadores para ajustar os parâmetros do controlador com base nas medidas de entrada e saída. Este artigo aborda o procedimento de forma direta utilizando a regra delta como estimador.

2.2 Métodos de Sintonia de Controladores PID

A sintonia PID é o ajuste dos parâmetros K_p , K_i e K_d para otimizar o desempenho do sistema. Encontrar a combinação certa desses parâmetros é relevante para garantir uma resposta rápida e estável do sistema em questão, seja em sistemas de controle industrial, automação ou robótica.

A sintonia adequada do PID é um desafio prático, muitas vezes realizado por meio de métodos experimentais ou algoritmos computacionais para garantir um desempenho eficiente e estável do sistema controlado.

2.2.1 Sintonia PID por métodos tradicionais

Souza (2013) declara que existem uma infinidade de métodos sintonia de controladores PID reconhecidos em processos industriais, como: “Ziegler e Nichols (1942), Cohen e Coon (1953) e Chien, Hrones e Reswick (1952), método da Integral do Erro (LÓPEZ et al., 1967), método Biggest Log- Modulus Tuning (LUYBEN, 1986)”. Logo abaixo uma breve descrição destes métodos:

- **Ziegler-Nichols (1942):** Este método envolve a realização de testes no sistema para determinar os parâmetros críticos, como a taxa de ganho (K_u) e o período de oscilação (T_u), a partir dos quais os parâmetros PID podem ser derivados.
- **Cohen e Coon (1953):** Esse método é uma variação do método de Ziegler-Nichols. Ele propõe uma fórmula para ajustar os parâmetros do controlador PID com base nos valores obtidos durante os testes de identificação do sistema.
- **Chien, Hrones e Reswick (1952):** Este fornece uma abordagem sistemática para a sintonia de controladores PID, utilizando modelos matemáticos do processo para determinar os parâmetros do controlador.
- **Método da Integral do Erro (LÓPEZ et al., 1967):** Este método se baseia na integral acumulada do erro ao longo do tempo. Ele visa ajustar a parte integral do controlador PID para atingir o equilíbrio dinâmico e minimizar o erro de regime permanente.
- **Método Biggest Log-Modulus Tuning (LUYBEN, 1986):** Este método se concentra em maximizar o módulo logarítmico do sistema para otimizar o desempenho do controlador PID.

Segundo Romão (1996) em controle, um sistema adaptativo é capaz de modificar seu comportamento em resposta a mudanças na dinâmica do processo e perturbações. Esses sistemas têm propriedades valiosas que podem ser incorporadas no projeto de novos controladores.

2.2.2 Sintonia PID por exame de partículas (PSO)

O algoritmo PSO não faz muitas hipóteses em relação ao problema específico, o que pode resultar em soluções não ótimas em determinadas circunstâncias. Essa característica permite que o PSO seja adaptado a uma variedade de problemas sem a necessidade de pré-suposições, apenas com métricas associadas ao problema em questão. (MEDEIROS; KRIPKA, apud SANTOS, L.R.R,2018).

As equações fundamentais do PSO são essenciais para a dinâmica do movimento das partículas. A eq.2 descreve a atualização da velocidade, influenciada pela melhor posição global e local, juntamente com constantes de intensidade de deslocamento. A eq.3 determina a obtenção da nova posição da partícula com base na posição atual e na velocidade (YANG, 2010 apud SANTOS, L.R.R,2018).

$$v_{id}[t + 1] = \omega v_{id}[t] + \varphi_1 R_{id1}[t](p_{id}^{best}[t] - p_{id}[t]) \dots + \varphi_2 R_{id2}[t](p_{igd}^{best}[t] - p_{id}[t]) \quad (2)$$

$$p_{id}[t + 1] = p_{id}[t] + v_{id}[t + 1] \quad (3)$$

No contexto específico deste artigo o PSO é aplicado à otimização dos parâmetros do controlador PID para melhorar seu desempenho em sistemas dinâmicos. Sendo apresentado os termos das equações do algoritmo:

- $v_{id}[t + 1]$: representa a velocidade da partícula "i" na dimensão "d" no instante de tempo "t + 1".
- ω : um parâmetro que controla a inércia da partícula.
- φ_1 e φ_2 : são constantes que controlam as melhores posições globais e locais.
- $R_{id1}[t]$ e $R_{id2}[t]$: são números aleatórios entre 0 e 1.
- $p_{id}^{best}[t]$: a melhor posição local da partícula "i" até o instante "t".
- $p_{igd}^{best}[t]$: a melhor posição global entre todas as partículas até o instante "t".
- $p_{id}[t + 1]$: representa a nova posição da partícula "i" na dimensão "d" no instante de tempo "t + 1".

Segundo SANTOS, L.R.R, 2018, a integração dos ganhos do controlador PID no contexto do PSO representa uma abordagem eficaz para otimizar o desempenho do controlador. Essa abordagem aproveita as capacidades do PSO na busca por soluções eficazes, direcionadas pelas funções custo.

2.2.3 Sintonia PID por redes neurais

De acordo com Silva et al (2019, pag.54), o aprendizado padrão-por-padrão (on-line) é uma estratégia de treinamento em que um modelo de aprendizado de máquina é atualizado incrementalmente, exemplo por exemplo, ao invés de ser treinado de uma só vez com um conjunto fixo de dados. Nesse método, cada exemplo de treinamento é apresentado individualmente ao modelo, que é ajustado com base nesse exemplo específico. Esse processo ocorre continuamente à medida que novos dados ficam disponíveis, permitindo uma adaptação dinâmica do modelo a mudanças nas distribuições de dados ao longo do tempo.

Apresenta desafios, como os dados são apresentados, considerações de memória disponível e a necessidade de lidar com conjuntos de dados desequilibrados. A escolha entre treinamento online e em lote depende das características específicas do problema e dos requisitos do sistema. (Silva et al,2019, pag.55).

Segundo MAGNUSSON (2018), uma rede neural artificial (RNA) tem dificuldade em interpretar a componente integral de um controlador PID, devido à sua natureza somatória. A rede neural é projetada para reconhecer padrões entre entradas e suas saídas correspondentes. No entanto, a parcela integral do controlador não exibe um padrão de saída consistente para uma entrada específica, podendo variar para a mesma entrada em momentos distintos.

O modelo de PID adaptativo proposto neste artigo considera as características e desafios citados em seu embasamento. Na seção 2.3, discute-se redes neurais em sua forma mais simples e como ocorre o treinamento.

2.3 Redes Neurais

As redes neurais são ferramentas poderosas em aprendizado de máquina, mesmo com apenas um neurônio. Esse modelo básico, conhecido como *Perceptron*, desempenha um papel fundamental ao separar classes linearmente. Ao receber entradas ponderadas e aplicar uma função de ativação, o neurônio aprende padrões e relações nos dados, ajustando seus pesos durante o treinamento para otimizar as previsões (DSA, cap. 6 ,2023).


Esse modelo segundo Silva et al (2019, pag.59) é aplicado em tarefas como classificação binária e regressão, e sua flexibilidade e capacidade de generalização fazem dele uma escolha valiosa em situações em que a complexidade do modelo deve ser controlada. No contexto de aprendizado de máquina, o uso de um único neurônio destaca a versatilidade das redes neurais, oferecendo uma abordagem eficaz para problemas mais simples. Essa simplicidade, por vezes, revela-se uma vantagem em termos de eficiência computacional, tornando-o uma opção viável em diferentes cenários.

2.3.1 Perceptron

Segundo CECCON (2020), pesquisadores se inspiraram no neurônio humano e suas sinapses no desenvolvimento de um modelo matemático que represente um neurônio artificial, entretanto mesmo nas redes neurais mais complexas, as relações entre as variáveis de entrada e de saída serão lineares, para resolver este problema e poder modelar relações não-lineares, os resultados de saída de cada camada são processados pelas denominadas funções *de ativação*.

A fig. 1 representa a evolução do modelo do Neurônio artificial denominado *Perceptron* expresso pela equação $y_k = \Phi(\sum_{K=1}^n x_K w_K + w_0)$, formando assim a menor rede neural possível com apenas um neurônio (CECCON D,2020).

Figura 1 – Modelo matemático Neurônio artificial.



Fonte: DAS (2022).

A partir deste modelo simplificado surge modelos mais complexos, com mais neurônios e topologias diferentes, para se utilizar funções ativação não-lineares deve se observar algumas características como:

- **Custo computacional:** Operações matemáticas lineares são computacionalmente simples.
- **Diferenciabilidade:** Durante o treinamento das redes neurais, seus pesos e seus bias são ajustados pelo mecanismo de *descida do gradiente*, que exige que cada operação matemática realizada em cada camada tenha sua derivada calculada.

- **Centradas em zero:** Os resultados que a função de ativação é capaz de produzir deve ter iguais probabilidades de ser positivo ou negativo para poder convergir.
- **Não produzir platôs:** Platôs são regiões do universo de resultados que tendem a ser constantes. Quando uma função tem regiões constantes, a derivada nessas regiões tende a zero, o gradiente tende a zero e a rede não é mais capaz de convergir.

2.3.2 Treinamento Rede

De acordo com Silva et al (2019, pag.60), o ajuste dos pesos e limiar do Perceptron é realizado por meio da regra de aprendizado. Resumidamente, se a saída produzida pelo Perceptron não coincide com a saída desejada, os pesos e limiares da rede serão atualizados proporcionalmente aos valores de seus sinais de entrada. Caso contrário, ou seja, se a saída produzida pela rede é igual ao valor desejado, os pesos sinápticos e limiar permanecerão inalterados. Esse processo é repetido sequencialmente para todas as amostras de treinamento, até que a saída produzida pelo Perceptron seja similar à saída desejada de cada amostra. Em termos matemáticos, as regras de ajuste dos pesos do neurônio podem ser expressas pela regra delta na eq.4:

$$W_i^{atual} = W_i^{anterior} + n(d^k - y)X_i^k \quad (4)$$

A taxa de aprendizagem n reflete quão rápido o processo de treinamento da rede será conduzido em direção à sua convergência. A escolha da taxa de aprendizado deve ser realizada com cautela para evitar instabilidades no processo de treinamento, sendo que normalmente se adotam valores pertencentes ao intervalo compreendido em $0 < n < 1$ (Silva et al, 2019, pag.63).

Posteriormente na seção 2.4 há apresentação de três métricas de avaliação de desempenho e suas características.

2.4 Índices de desempenho

A escolha do índice de desempenho mais adequado depende das características específicas do sistema de controle. Por exemplo, se o sistema é

sensível a erros iniciais ou críticos, o ISE pode ser um bom índice de desempenho. Se o sistema é sensível a erros que persistem por um longo período, o ITAE pode ser um bom índice de desempenho (FERMINO, 2014). Os índices de desempenho podem ser utilizados de forma isolada ou em conjunto. A seguir são discutidas as métricas de desempenho IAE na subseção 2.1.3.1.

2.4.1 Integral do valor absoluto do erro (IAE):

O Índice IAE refere-se a uma métrica de desempenho de controladores em que se almeja analisar o resultado do erro independente do tempo de convergência.

Essa métrica se destaca por sua abordagem que envolve um amortecimento ponderado e uma resposta transitória efetiva. Apesar de não apresentar uma definição rigorosa dos parâmetros. (FERMINO, 2014). Sendo calculado pela eq. 5, sugerindo uma ênfase na consideração da magnitude absoluta dos erros ao longo do tempo.

$$IAE \int_0^T |e(t)| dt \quad (5)$$

- I: Representa uma integral definida ao longo do tempo, de $t = 0$ até $t = T$
- A: Considera apenas a magnitude
- E: Apresenta a diferença entre a resposta do sistema e a referência desejada

2.4.1 Integral do quadrado do erro (ISE):

O índice ISE refere-se a uma métrica de desempenho de controladores em que se almeja analisar o resultado dos erros de maior magnitude.

Essa métrica é um indicador de desempenho que enfatiza a minimização de grandes desvios em sistemas de controle. Ele atribui maior importância aos erros que possuem maior valor absoluto, o que o torna relevante em contextos nos quais a atenuação rápida de grandes erros é necessária (FERMINO, 2014), o qual é calculado pela eq. 6:

$$ISE = \int_0^T e^2(t) dt \quad (6)$$

- I: Representa uma integral definida ao longo do tempo, de $t = 0$ até $t = T$
- S: Considera o termo a seguir elevado ao quadrado
- E: Apresenta a diferença entre a resposta do sistema e a referência desejada

2.4.2 Integral do tempo multiplicado pelo valor absoluto do erro (ITAE):

O índice ITAE refere-se a uma métrica de desempenho de controladores onde se almeja analisar o resultado do erro conforme aumenta o tempo de convergência. É um índice de desempenho que penaliza os erros que ocorrem no final da resposta transitória de um sistema de controle. Levando em conta não apenas a magnitude, como no IAE, mas também a duração desses erros antes da convergência. A ITAE possui uma maior capacidade de escolha nos parâmetros em relação a ISE (FERMINO, 2014), e é calculada pela eq. 7:

$$ITAE = \int_0^T t|e(t)| dt \quad (7)$$

- I: Representa uma integral definida ao longo do tempo, de $t = 0$ até $t = T$.
- T: Considera o tempo como multiplicador.
- A: Considera apenas a magnitude.
- E: Apresenta a diferença entre a resposta do sistema e a referência desejada.

3 METODOLOGIA

A premissa em que a utilização de um controle PID adaptativo fundamentado em pesquisas de redes neurais é capaz de lidar com as variabilidades do processo de forma mais eficaz do que as técnicas de sintonia do controle PID tradicionais. Por meio dessa proposição, a intenção é demonstrar a adaptação dos pesos do controlador PID, influenciada pela regra de delta, aprimorando a habilidade do controlador em otimizar o desempenho do sistema de maneira autônoma.

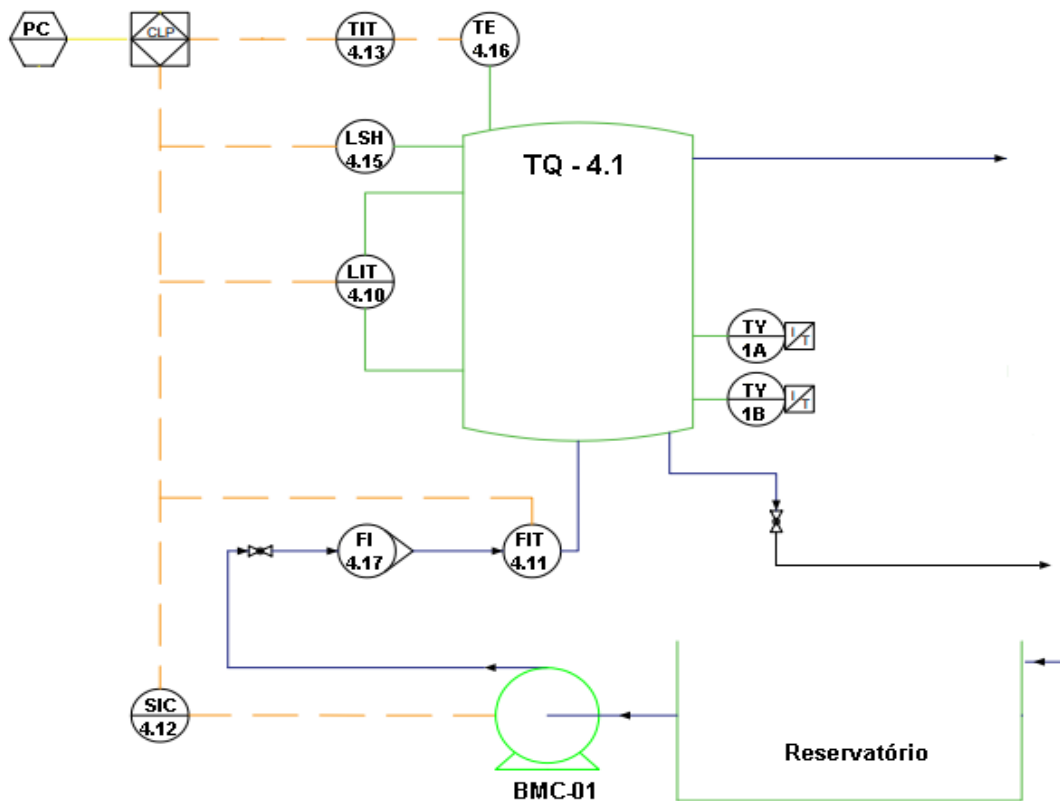
A metodologia proposta inicia-se com a fase de aquisição de dados, envolvendo a implementação prática de dados relevantes para o controle de nível. Em seguida, é determinado o modelo matemático do processo para definição dos parâmetros de controle PID, abordando diferentes métodos de sintonia.

Introduz-se então a ideia do PID adaptativo, em que há um ajuste automático dos parâmetros com base nas condições em tempo real. Finalmente, na etapa de confronto, realiza-se uma análise comparativa entre os métodos propostos, avaliando a robustez do sistema de controle adaptativo.

3.1 Experimentação e Aquisição de Dados de Controle de Nível

Os dados foram coletados em uma planta didática com componentes industriais, a qual tem por objetivo manter o nível de um tanque pulmão de 500 mmH_2O estável e minimizar perturbações do processo para garantir uma vazão laminar, cujo diagrama P&D é apresentado na fig. 2.

Figura 2 – Diagrama P&D.




Fonte: Elaborado pelo autor (2023)

3.1.1 Características do sistema

O nível é controlado utilizando o controlador Siemens Step 7 1200 e monitorado via supervisão desenvolvido no software Elipse E3 mostrado na fig. 3 em que as telas estão conforme a norma ISA 101. As vazões do processo foram variadas em 20%, 60%, 80%, e 100% cuja vazão máxima é de 20 l/min e mínima controlável considerando velocidade mínima para se realizar a transferência é de 4 l/min .

Figura 3 – Supervisório



Fonte: Elaborado pelo autor (2023)

Os dados adquiridos incluíram o nível do tanque, vazão de saída, velocidade da bomba e valores de referência. Os registros foram exportados no formato CSV a partir do banco de dados do supervisório com intuito de trabalhar com os dados coletados via software MATLAB, prosseguindo para subseção 3.1.2 com definição da função de transferência.

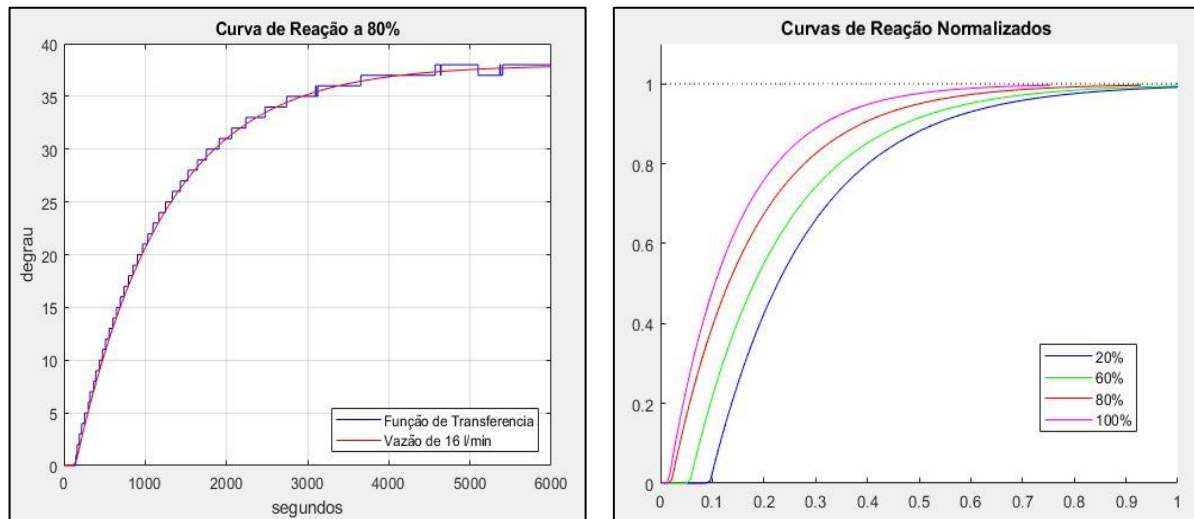
3.1.2 Função de transferência.

Após aquisição dos dados do sistema de controle de nível, eles foram normalizados para facilitar compreensão e análise de simulações do comportamento de resposta deste processo.

Os parâmetros da função de transferência, como ganho, tempo morto e constante de tempo, foram estimados com base nos dados coletados em diferentes vazões, com objetivo de comparar a resposta em diferentes consumos.

Sendo apresentado na fig. 4 à esquerda, a resposta do sistema a 80% de vazão e à direita diferentes vazões do processo já normalizadas, podendo ser observado que mesmo em diferentes vazões mantém o comportamento.

Figura 4– Curva de reação.



Fonte: Elaborado pelo autor (2023)

Sendo possível ver a variação do sistema em relação ao tempo de resposta e na estabilidade do sistema. Entretanto para a análise de controle, limitou-se a função de transferência de maior vazão abstraída da eq. 8, dada pela ferramenta “*System Identification*” do Matlab com objetivo de determinar um controle mais robusto.

$$G(s) = \exp(-1.5s) \frac{1.99}{194.6s + 1} \quad (8)$$

É possível perceber pelo gráfico e função de transferência que o sistema em questão é de primeira ordem com atraso. Deixando explícito que para aquisição dos dados foram considerados respostas em que havia menores perturbações, com objetivo de se obter função que refletisse apenas o consumo. Em seguida determinou-se na seção 3.2 os parâmetros por meio das sintonias definidas anteriormente dos controladores.

3.2 Definição dos Parâmetros de Controle PID

Com o intuito de comparar o controle PID adaptativo com outros métodos primeiramente foi necessário determinar os ganhos K_p , K_i e K_d . Para esse fim, foi utilizado quatro métodos com abordagem diferentes, sendo o primeiro de forma prática experimental, o segundo a partir do método consagrado de sensibilidade limite proposto por Ziegler e Nichols (FERMINO, 2014), terceiro utilizando a Otimização por Enxame de Partículas (PSO), e quarto o autoajuste do controlador Siemens Step 7 1200 utilizado no processo em investigação.

3.2.1 Empírico

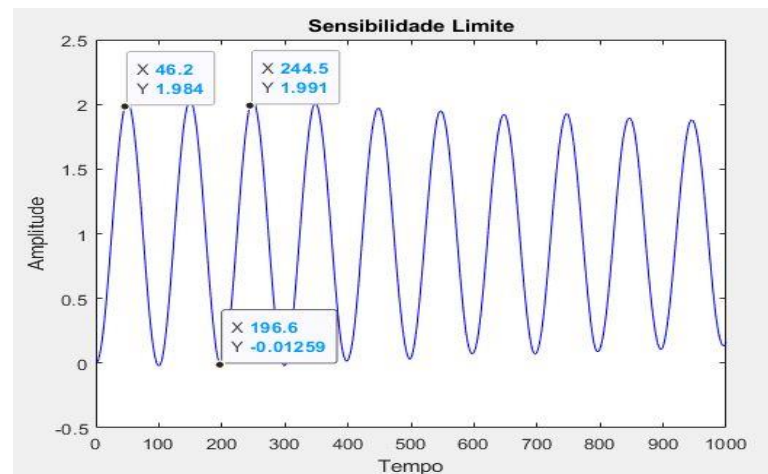
A sintonização empírica de um controlador PID se inicia com a constante proporcional (K_p) que influencia a resposta imediata à diferença entre a saída desejada e a saída real do sistema. Inicialmente, com um valor baixo, e aumenta-se progressivamente, observando o tempo de resposta e as oscilações do sistema. Em seguida, ajusta-se a constante integral (K_i) para minimizar o erro em regime estacionário. Primeiramente, com um valor de K_i igual a zero e aumenta-se gradualmente, monitorando constantemente o sistema para evitar instabilidades. Por fim, ajusta-se a constante derivativa (K_d) para aprimorar a estabilidade e reduzir oscilações. Da mesma forma, o ajuste de K_d começa com o valor zero e incrementa-se gradativamente. A sintonização é iterativa, implicando paciência e atenção a cada mudança.

3.2.2 Método de sensibilidade limite

Este método foi proposto por Ziegler e Nichols sendo utilizado em processos de malha fechada nos quais possa ser aplicado um ganho que apresente uma oscilação periódica em sua saída amplitudes e períodos estáveis (FERMINO, 2014).

Determinou-se o ganho crítico (K_u) mediante ao pico estável e o período crítico (T_u) pelo tempo do de oscilação explicito na fig. 5 normalizados por unidade, a partir da função de transferência obtida pelos dados aquisitados do sistema.

Figura 5 – Ganho Critico.



Fonte: Elaborado pelo autor (2023)

Em sequência com os valores de K_u e T_u é possível calcular os ganhos do controlador por meio da tabela 1.

Tabela 1– Metodo de oscilação critica.

Controlador	K_p	T_i	T_d
P	$0,5K_u$	-	-
PI	$0,4K_u$	$0,8T_u$	-
PID	$0,6K_u$	$0,5T_u$	$0,125T_u$


Fonte: Ziegler e Nichols, 1942, apud Fermino, 2014

Após simulação via script no Matlab foi autenticado parâmetros K_u e T_u com o processo em análise, tendo propósito de validar a função de transferência e comparar comportamento dos ganhos simulados com os dados reais a uma vazão de 20 $\frac{l}{min}$ apresentado na fig. 6.

Por meio do cálculo de desvio padrão dado pela eq. 9, em uma população de 7082 amostras, totalizando 11 minutos e 48 segundos, resultando em um desvio padrão de 2,3% em um conjunto de 7082 dados, no qual apresenta em valor real de 11,5 mmH_2O de desvio padrão.

$$\sigma = \sqrt{\frac{\sum(x_i - \mu)^2}{N}} \quad (9)$$

Figura 6– Testes em bancada.



Fonte: Elaborado pelo autor (2023).

3.2.3 Otimização por Enxame de Partículas (PSO)

Utilizando as funcionalidades pré-existentes no manual do Matlab para o algoritmo de enxame de partículas, apenas foi necessário realizar alguns ajustes de parâmetros, como o tamanho da população, o número máximo de iterações, limites superior e inferior, já que esses parâmetros afetam diretamente a convergência do algoritmo, sendo realizado primeiramente de modo experimental.


A escolha dos limites do sistema não foi um desafio, pois na sintonia empírica obteve-se conhecimento prévio sobre as faixas de valores plausíveis. Segundo SANTOS (pág. 42, 2018), “Durante a operação do PSO, as partículas viajam em um espaço de interesse com determinadas coordenadas”, a partir disto foi selecionado o maior valor alcançado para um processador i5-4200U 2.30 GHz e 12GB de RAM.

O loop de otimização do PSO foi executado aproximadamente 20 vezes, para obter bons resultados, com parâmetros iniciais aleatórios e, sendo reconhecido com base no custo mínimo obtido, comparado com os índices de desempenho calculados durante a cada interação.

Com resultados relevantes foi realizado um segundo loop com vinte interações para avaliar resultado das iterações do loop PSO com os parâmetros determinados, sendo tamanho da população de 60 e número máximo de iterações de 30000, não sendo mais aumentar devido limitações de processamento.

Na fig.7 é possível visualizar resultado após 17:32:25,1 horas de simulação dos índices ITAE, IAE, ISE e custo mínimo obtido sendo o melhor resultado na decima oitava interação determinado pelo menor valor da média dos índices.

Figura 7– Treinamento PSO.



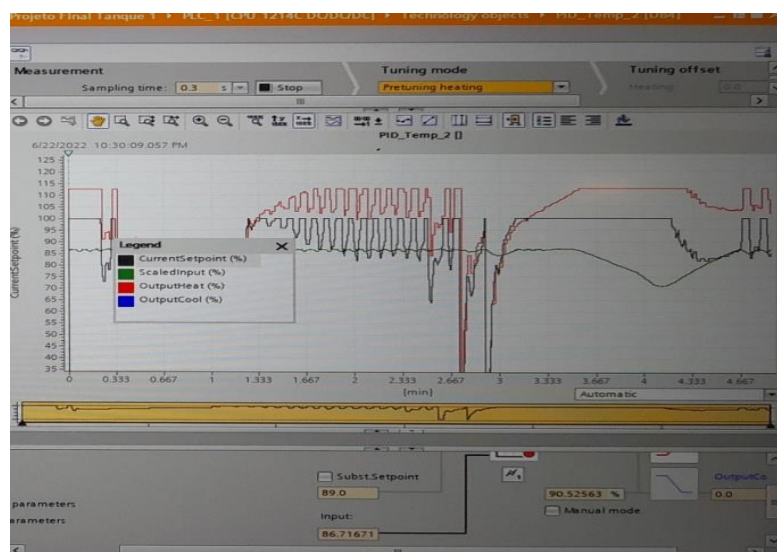
Fonte: Elaborado pelo autor (2023)

3.2.4. Autoajuste do controlador Siemens Step 7 1200

A ferramenta de autoajuste do controlador exposta na fig. 8 determina a resposta um degrau na saída de um controle na identificação do ponto de inflexão. Os parâmetros do controlador PID são calculados com base na inclinação máxima e no tempo de resposta do sistema controlado.

Os valores ideais dos parâmetros PID são obtidos através da execução de duas etapas: pré-ajuste e ajuste fino. Quanto mais estável for o valor real do processo, mais fácil e preciso será o cálculo dos parâmetros PID. Ruídos no valor real são aceitáveis desde que o sinal de interesse seja significativamente maior que o ruído (SIEMENS AG, 2017, pag.41).

Figura 8– Tuning mode Step 7 1200



Fonte: Elaborado pelo autor (2023)

Seguindo as orientações do manual do fabricante para realizar a sintonia de pré-ajuste e ajuste fino armazenou os dados. Sendo possível comparar na tabela 2 a variação dos métodos de ganhos fixos utilizados. O controle PI foi predominante, sendo excluído da tabela o controle PID adaptativo devido à sua flutuação de valores.

Tabela 2– Ganhos por unidade

Método	K_p	K_i	K_d
Empírico	0.3	0.02	0
Sensibilidade lim.	0.9	0.006	0
PSO	0.75	0.01	47.68
Autotuning	0.72	0.015	0

Fonte: Elaborado pelo autor (2023)

3.3 PID adaptativo Proposto

A fim de compreender essa abordagem, é importante realizar uma análise dos parâmetros de um controlador PID discreto. Esse controlador é estruturado em torno de três componentes: Proporcional (P), Integral (I) e Derivativo (D), frequentemente denotados como K_p , K_i e K_d . Estes elementos desempenham funções essenciais na regulação de sistemas, ajustando-se para assegurar que o desempenho do sistema corresponda às expectativas estabelecidas.

No contexto deste estudo, apresenta uma abordagem que implica uma analogia entre os coeficientes Kp, Ki e Kd e os parâmetros ajustáveis em uma rede neural. Cada um desses coeficientes é equiparado a um peso correspondente em um contexto de aprendizado de máquina. Essa perspectiva conceitual nos permite explorar as afinidades entre o controle PID e os princípios subjacentes ao funcionamento de redes neurais.

Por meio dessa proposta, a intenção é demonstrar a adaptação dos pesos do controlador PID por meio da regra delta, e para este objetivo se faz necessário algumas ponderações.

Segundo Romão,1996, em aplicações digitais utiliza se o controlador PID discreto incremental dado pela eq. 10, a partir da relação da eq. 11 foi realizada a manipulação matemática para dispor os parâmetros do controlador Kp, Ki e kd em evidencia como mostrado na eq. 12.

$$\Delta u(t) = Kp \left[e(t) - e(t - 1) + \frac{T_s}{T_i} e(t) + \frac{T_d}{T_s} (e(t) - 2e(t - 1) + e(t - 2)) \right] \quad (10)$$


$$\text{Onde } T_i = \frac{K_p}{K_i} \quad \text{e} \quad T_d = \frac{K_d}{K_p} \quad (11)$$

$$\Delta u(t) = Kp \cdot (e(t) - e(t - 1)) + Ki \cdot (T_s \cdot e(t)) + Kd \cdot \left(\frac{e(t) - 2e(t - 1) + e(t - 2)}{T_s} \right) \quad (12)$$

A partir destas asserções foi realizado a analogia entre o controle PID e as redes neurais exibida na figura 9 inspirado na pesquisa de Santos L.R.R(2018) em sintonia PID utilizando Algoritmos de Controle de Potência Distribuídos (DPCA) em Rede Opticas Passivas (PON), utilizando assim a regra delta eq.1 em algumas literaturas dado pela eq. 13 para atualização dos ganhos onde:

$$W_n = W_n + \alpha (Y_n - sp(n))X_n \quad (13)$$

Figura 9 - PID Perceptron.



Fonte: adaptado DAS (2022).

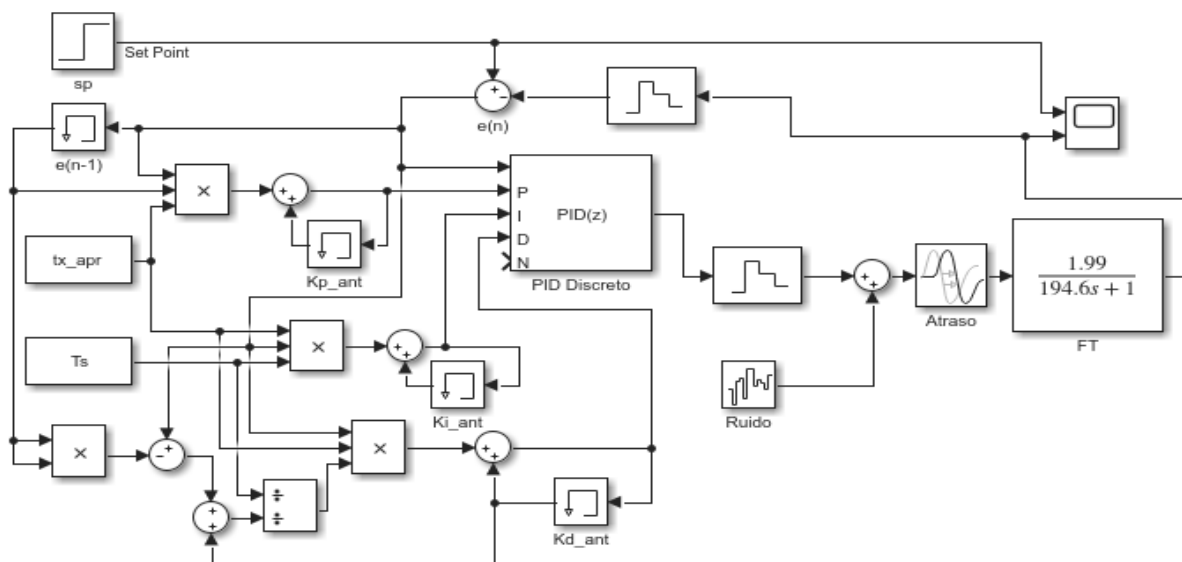
- Wn : Ganhos Kp, Ki e kd .
- α : Coeficiente de aprendizado.
- Yn : Saida do processo.
- $sp(n)$: Saida desejada.
- Xn : Entrada fundamentada na eq. 12.

Após as definições e abstrações foi realizado simulações na ferramenta simulink do Matlab utilizando a função de transferência dada pela eq. 8, realizando a atualização dos ganhos pela regra delta sendo a entrada análoga de cada ganho fundamentada pela eq. 12 e exibida na fig. 9 modelo adequado para realizar a adaptação dos ganhos.

Salientando que a taxa de amostragem (T_s) utilizada foi a mesma utilizada na aquisição dos dados da fig. 4 com objetivo de encontrar um coeficiente de aprendizado aproximado para o processo analisado.

Apresentado na fig. 10 o resultado da organização dos blocos de controle utilizados na simulação do PID adaptativo, de forma simplificada foi acrescentado a regra delta nas entradas do PID discreto.

Figura 10 - PID Adaptativo Simulink.




Fonte: Elaborado pelo autor (2023)

A princípio assim como na sintonia empírica utilizou se com um valor baixo de coeficiente de aprendizado e inserido o um degrau de 70%, aumentando assim

gradualmente a cada teste, e avaliando a resposta após cerca de 20 testes pode perceber visualmente resultados satisfatórios e continuando a aumentar a taxa passou a existir um sobressinal, assim decrementando novamente até encontrar resultado visual satisfatório apresentado na fig. 11 juntamente com a evolução dos ganhos K_p , K_i e K_d .

Figura 11- Resposta degrau PID adaptativo



Fonte: Elaborado pelo autor (2023)

3.4 Análise do PID adaptativo.

Inicialmente, foram realizadas diversas simulações para análise gráfica dos resultados, avaliando eventuais discrepâncias nas sintonias.

Após várias análises gráficas serem feitas, foi possível fazer algumas asserções, como por exemplo:

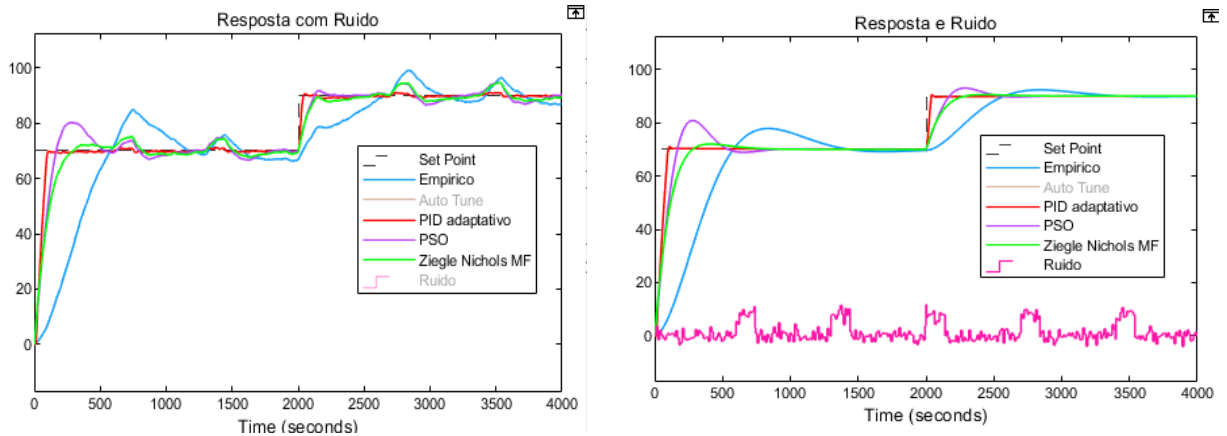
- as diferentes recuperações de cada tipo de sintonia;
- a eficiência esperada do método legitimado de sensibilidade limite;
- como o método empírico se mostrou ineficiente em relação aos demais.

No entanto, não é possível validar o desempenho da sintonia do controlador adaptativo sem aplicar métricas de avaliação.

A fig. 12 exibe a mudança no valor de referência, nos tempos 0 segundos e 2000 segundos. A imagem da esquerda mostra uma perturbação periódica de amplitude de 10% a cada 600 segundos e uma aleatória entre -5% e 5% de

amplitude por todo tempo. A imagem da direita mostra o sinal puro, separado das perturbações inseridas no sistema.

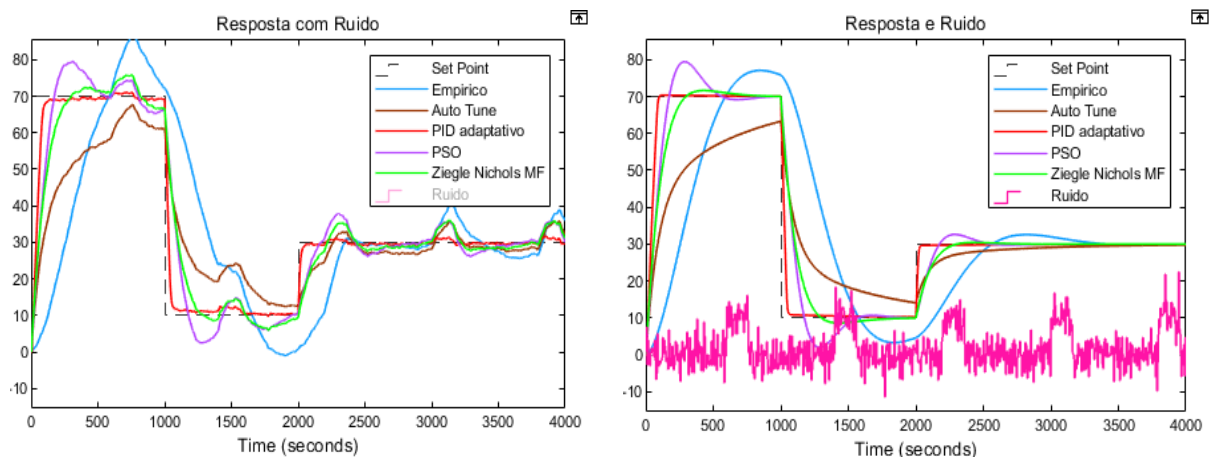
Figura 12 - Resposta PID adaptativo.



Fonte: Elaborado pelo autor (2023)

Na fig. 13 apresenta-se semelhante, contudo, com diferentes de valores de referência, nos tempos 0 segundo, 1000 segundos e 2000 segundos, também modificado a perturbação periódica de 15% de amplitude em intervalões de 800 segundos e perturbações aleatórias entre -5% há 10%.

Figura 13 - Resposta PID adaptativo.

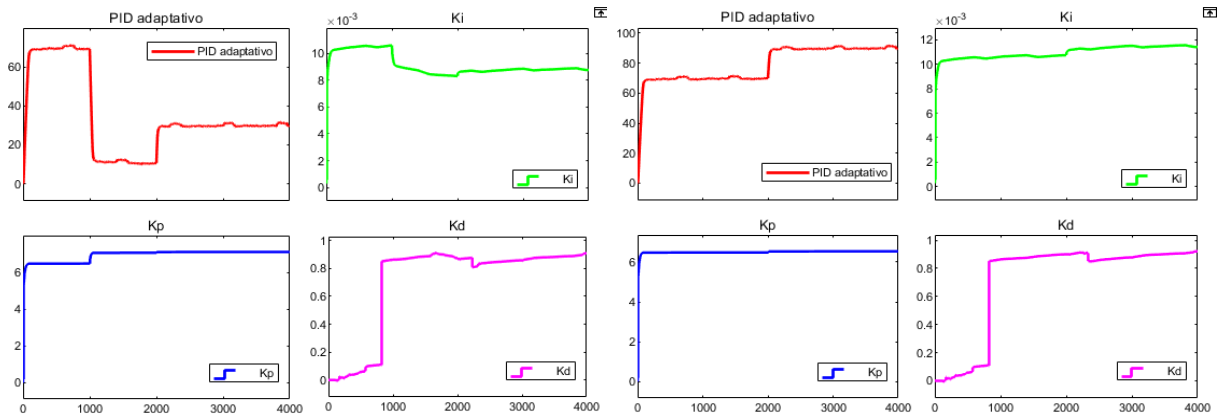


Fonte: Elaborado pelo autor (2023)

Após diversas simulações realizando modificações de valores de referência, inserção de perturbações no sistema. Foi analisado a evolução dos parâmetros Kp ,

K_i e K_d dispostos na fig. 14, podendo ser observado o comportamento adaptativo do controlador.

Figura 14- Adaptação K_P , K_I e K_d .



Fonte: Elaborado pelo autor (2023)

Considerando a variação dos valores de referência nos tempos 0, 1000 e 2000 segundos, observa-se o incremento significativo de K_P e K_i ao iniciar, em 1000 segundos a variação agressiva de K_d após a mudança do valor de referência e o decremento em k_i de forma periódica, nos momentos das perturbações inseridas. Apresentando a seção 4 os resultados obtidos nas métricas de desempenho evidenciando alguns detalhes importantes.

4 APRESENTAÇÃO E DISCUSSÃO DOS RESULTADOS


Nesta seção é apresentado, as respostas dos controladores, destacando variações e perturbações. Os resultados, são apresentados na Tabela 3, comparado os diferentes métodos de sintonia do sistema, revelando o método com índices mais baixos em todas as métricas, indicando sua eficácia na minimização de erros.

4.1 Desempenho dos Controladores

Analisando o índice IAE, como descrito em literatura, apresentou uma resposta ponderada nas transições, podendo ser visto na fig. 14, resultante do cálculo da IAE da resposta obtida na fig. 13, onde é apresentado variações dos valores nos tempos em 0, 1000 e 2000 segundos, perturbações periódicas e aleatórias inseridas no sistema.

Na análise de sobressinal, apenas é perceptível uma leve ondulação em resposta ao ruído na fig.14. Em relação às perturbações, é perceptível uma leve inclinação. Em algumas simulações, só foi possível ver essas características em conjunto de dados armazenados no workspace do MATLAB.


Figura 14 - Integral do valor absoluto do erro



Fonte: Elaborado pelo autor (2023).

Analisando o índice ISE, que atribui mais peso aos erros de maior magnitude, é possível ver na fig. 15 o incremento significativo do índice na mudança dos valores de referência, seguindo o eixo do tempo em 0, 1000 e 2000 segundos. Em relação ao sobressinal, é visível apenas uma leve ondulação, não sendo possível avaliar de forma visual a influência das perturbações no gráfico.


Figura 15 - Integral do quadrado do erro.



Fonte: Elaborado pelo autor (2023)

Diferente do índice ISE, o índice ITAE combina o conceito dos dois métodos e incrementa a ação do tempo, penalizando assim erros que ocorrem no final da resposta transitória, ou seja, erros que perduram no tempo. Isso pode ser visto na fig. 16, onde os índices continuam a incrementar significativamente nas sintonias que atrasaram a minimizar o erro após a transição dos valores de referência.

Figura 16 - Integral do tempo multiplicado pelo valor absoluto do erro



Fonte: Elaborado pelo autor (2023).

Essas métricas fornecem uma medida quantitativa do desempenho do sistema em diferentes aspectos, conforme índices calculados e normalizados por unidade (PU) apresentado na Tabela 3. O IAE prioriza grandes erros instantâneos, o ISE penaliza mais fortemente erros grandes de longo prazo, e o ITAE combina ambos, considerando também a variação ao longo do tempo. Analisando os resultados da tabela 3, observando que o método que apresenta os valores mais baixos em todas as métricas é geralmente considerado o mais eficaz para a sintonia do sistema.

Tabela 3 – Índice Final normalizados em PU da figura 13

	IAE	ISE	ITAE
Empírico	1	1	1
Sensibilidade limite	0,292	0,276	0,076
PSO	0,311	0,288	0,083
Autotuning	0,618	0,553	0,304
Adaptativo	0,146	0,109	0,012

Fonte: Elaborado pelo autor (2023).

4.2 Conclusões

O método empírico em aplicação prática se mostrou promissor e satisfatório em primeiro momento, mas após a inserção de mudança de valor de referência e de perturbações externas deixou evidente suas limitações. Já o método de sensibilidade limite legitimado pela literatura, correspondeu com resultados excelentes, contudo em resposta em relação as perturbações inseridas, não alcançou o melhor resultado.

Apesar do algoritmo PSO apresentar ótimos resultados em resposta as perturbações inseridas, não se destacou nos resultados em relação aos índices de desempenho. A sintonia adaptativa obteve os melhores resultados nos índices, além de excelente resultado em relação as perturbações inseridas, um menor sobressinal e acomodação superior em relação aos outros métodos.

5 CONSIDERAÇÕES FINAIS

O método empírico não superou nenhum dos demais métodos, embora houvesse expectativa de aproximação destes.

A expectativa em torno do enxame de partículas em estar entre os dois primeiros era grande, pelo fato de que a quantidade de cálculos realizados ser muito maior em relação aos outros métodos utilizados.

O método de sensibilidade limite superou as expectativas, demonstrando um desempenho satisfatório mesmo com ganhos fixos. Sua recomendação em processos aplicáveis deve-se à sua simplicidade e eficiência.

Por outro lado, o método PID adaptativo destacou-se, tanto no tempo de acomodação quanto no menor sobressinal. Além disso, exibiu uma excelente recuperação após a introdução de perturbações no sistema, tornando-o uma escolha aceitável em situações que demandam maior precisão de controle. Vale ressaltar que um controle mais preciso resulta em uma aplicação mais eficiente da energia necessária para o controle.

Como perspectiva para futuros estudos, sugere-se a investigação do PID adaptativo em sistemas de maior ordem e/ou que empregam outras variáveis do processo para a atualização dos parâmetros de controle

REFERÊNCIAS

CECCON D. **Função de ativação: Definição e quando usar cada uma**. Disponível em: <https://iaexpert.academy/2020/05/25/funcoes-de-ativacao-definicao-caracteristicas-e-quando-usar-cada-uma/> . Acesso em 26 de março de 2023.

DSA, **Deep Learning Book**. Disponível em: <https://www.deeplearningbook.com.br/>. Acesso em 01 de março de 2023.

FERMINO F. **Estudo comparativo de métodos de sintonia de controladores PID**. Trabalho de conclusão de curso, [Escola de Engenharia de São Carlos](#) (2014). Disponível em: <http://www.tcc.sc.usp.br/tce/disponiveis/18/180500/tce-14012015-162330/?&lang=br>. Acesso em 12 de setembro de 2023.

MAGNUSSON, Matheus. **Comparativo entre controlador PID e redes neurais artificiais no controle de atitude de um quadricóptero**. 2018. 96 f. Trabalho de Conclusão de Curso (Graduação) - Universidade Tecnológica Federal do Paraná, Pato Branco, 2018. Disponível em : <http://repositorio.utfpr.edu.br/jspui/handle/1/14616> . Acesso em 15 de outubro de 2023.

Souza, J.O.O.S. **Metaheurísticas aplicadas na sintonia de controladores PID: estudo de casos**. Unisinos, 2013 Disponível em: <http://repositorio.jesuita.org.br/handle/UNISINOS/4457>. Acesso em 10 de setembro de 2023.

SANTOS, L.R.R. **Sintonia adaptativa de algoritmos de controle de potência PID em redes ópticas passivas de próxima geração baseada em inteligência computacional**. Dissertação (Mestrado em Engenharia Elétrica). Universidade Tecnológica Federal do Paraná, Cornélio Procopio, 2018. Disponível em: <https://repositorio.utfpr.edu.br/jspui/handle/1/3369>. Acesso em 03 de agosto de 2023.

Santos, V. T. S. **Estudo experimental da força de impacto e do coeficiente de descarga de bocais ejetores utilizados na perfuração de poços de petróleo** Trabalho de conclusão de curso, Universidade Tecnológica Federal do Paraná (2014). Disponível em: https://riut.utfpr.edu.br/jspui/bitstream/1/10274/3/CT_COEME_2014-1_22.pdf. Acesso em 05 de novembro de 2023.

SIEMENS AG. **Módulo TIA Portal 032-500 Valores analógicos no SIMATIC S7-1500**. www.automation.siemens.com, 2007. Disponível em: <https://www.automation.siemens.com/sce-static/learning-training-documents/tia-portal/advanced-programming-s7-1200/sce-051-300-pid-control-s7-1200-r1709-en.pdf> Acesso em: 22 maio 2023.

Silva, I. N.; Spatti, D. H.; Andrade, R.; Flauzino, R. A. **Redes Neurais Artificiais para engenharia e ciências aplicadas**. Universidade de São Paulo. 2ª edição revisada e ampliada. São Paulo: Artliber Editora Ltda., 2019. Disponível em: https://artliber.com.br/amostra/redes_neurais.pdf. Acesso em: 22 outubro 2023

Sousa, L. T. D. M. D., & Roehle, R. A. F. D. O. **Aplicação dos conceitos de engenharia de processos: projeto de equipamentos industriais**. Trabalho de conclusão de curso, Graduação em Engenharia Química da Universidade de Brasília (2020).

ROMÃO, Wesley et al. **Análise e projeto de controladores PID adaptativos baseados em estimação de parâmetros: um estudo de caso**. 1996. Disponível em: <https://repositorio.ufsc.br/bitstream/handle/123456789/158052/104647.pdf>. Acesso em: 22 outubro 2023

E-TEC Revista de Tecnologia e Ciência

VOLUME 4

2024



WWW.UNISENAIPR.COM.BR

