

APLICAÇÃO DE TÉCNICAS DE INTELIGÊNCIA ARTIFICIAL PARA CONTROLE DE CONVERSOR DC-DC

Gabriel Del Monte Schiavi Noda¹ (IC), Robson Bauwelz Gonzatti¹ (PQ)

¹Universidade Federal de Itajubá - UNIFEI

Palavras-chave: Aprendizado de máquina. Conversor DC-DC. Eletrônica de potência. Rede neural artificial. Sistemas embarcados.

Introdução

Os conversores DC-DC do tipo *buck* são elementos fundamentais em sistemas na área de eletrônica de potência, sendo amplamente utilizados para reduzir níveis de tensão de alimentação em fontes embarcadas, sistemas fotovoltaicos e eletrônica de consumo geral. O funcionamento básico deste conversor baseia-se no chaveamento controlado de um componente semiconductor, como por exemplo um MOSFET (*Metal Oxide Semiconductor Field Effect Transistor*), em conjunto com um indutor e um capacitor, sendo este para a filtragem do sinal, de modo a converter uma tensão de entrada, denominada V_{in} , para uma tensão média de saída, denominada V_{out} , ajustada pelo ciclo de trabalho de um sinal modulado por largura de pulso aplicado ao circuito. A dinâmica deste conversor é considerada como não-linear e é sensível a variações dos parâmetros do circuito, como indutores, capacitores e resistências parasitas, tornando o projeto em uma tarefa crítica em aplicações.^[01]

Em geral, controladores do tipo proporcional-integrativo (PI) são utilizados em aplicações industriais e pesquisas devido à sua simplicidade de implementação, capacidade de eliminação de erro em regime permanente e resposta rápida à variações no sinal de entrada. Entretanto, este controlador possui ganhos fixos que devem ser recalculados sempre que há uma alteração nas características do circuito, o que ocasiona uma limitação na adaptabilidade do sistema como um todo.

Como alternativa a este controlador, as redes neurais artificiais (RNA) têm sido estudadas em relação ao controle de conversores, devido à sua capacidade de modelar relações não-lineares e se adaptarem a mudanças dinâmicas do sistema em tempo real. Diferentemente dos controladores PI que possuem ganhos fixos, as RNAs podem ser projetadas para ajustar seus pesos de forma contínua, buscando uma resposta eficiente a variações nos parâmetros do

circuito.^[02]

Deste modo, o projeto estuda diferentes tipos de controladores baseados em técnicas de inteligência artificial aplicadas ao controle do conversor *buck* buscando o objetivo de avaliar a estabilidade e a capacidade de adaptação do sistema em relação a variações dos componentes utilizados. Como hipótese central, tem-se que controladores treináveis e com capacidade de aprendizado em tempo real possam manter desempenho estável sem a necessidade de atualizar os parâmetros do controlador, compensando-se automaticamente de acordo com variações no circuito.

Metodologia

Com o objetivo de realizar comparações diretas entre os diferentes tipos de controladores durante o projeto, foram implementados dois tipos de controladores, o proporcional-integrativo e o baseado em rede neural artificial, ambos aplicados para o conversor *buck*, demonstrado topologicamente pela Figura 01.




Figura 01 - representação topológica do conversor *buck*

Fonte: VERDE et al.^[03]

O algoritmo do controlador PI, representado pela Figura 02, foi implementado de forma discreta recursiva baseando-se em uma diferença finita com coeficientes pré-calculados adotados no código-fonte utilizado pelo microcontrolador. A lei de controle conceitual é baseada na equação 01.^[04]

$$u[k] = K_p * e[k] + K_i * \sum_{i=0}^k e[i] * \Delta t \quad (01)$$

Porém considerando as limitações do ambiente

“Do conhecimento acadêmico à transformação sustentável: inovação com validação científica”

microcontrolado, foi utilizada uma versão onde a lei de controle foi baseada na equação 02, onde os coeficientes para esta equação foram definidos e ajustados unicamente para o conversor utilizado.

$$u[k] = (b_0 * e[k]) + (b_1 * e[k - 1]) - (a_1 * u[k - 1]) \quad (02)$$




Figura 02 - controlador PI

Fonte: Embarcados^[05]

Os algoritmos baseados em inteligência artificial foram separados em duas versões, tal que a primeira versão experimental foi implementada com um único neurônio e a segunda versão foi implementada com cinco neurônios, com três estando na primeira camada e os outros dois na segunda e última camada da rede. Os testes iniciais com estas técnicas serviram como prova de conceito para verificar cálculos e a atualização de pesos em tempo real, já a rede neural implementada utiliza uma rede do tipo *feedforward* na topologia 3-2, representada topologicamente pela Figura 03, para balancear a capacidade de modelagem e custo computacional. A saída da rede neural é convertida diretamente em ciclo de trabalho para a modulação de largura de pulso, de modo que toda a rotina de cálculos e treinamento é feita em tempo de execução no programa utilizado pelo microcontrolador.




Figura 03 - rede neural com topologia 3-3

Fonte: CARVALHO^[06]

Durante a implementação, as entradas fornecidas à RNA são: *BIAS* (valor constante), tensão de saída medida e a corrente medida, sendo que estas medições são normalizadas no intervalo fechado entre [-1; 1]. Para as ativações dos neurônios, são utilizadas funções *ReLU*, onde a saída é igual a 0 caso a entrada seja negativa e igual a entrada caso o valor seja positivo, no aprendizado e para a função de saída é utilizada uma função *ReLU* com limitação em valor unitário.^[07]

Os pesos da rede neural são inicializados de

forma pseudo-aleatória, com exceção da constante *BIAS* que é inicializada com um pequeno valor positivo garantindo saídas iniciais seguras. Após o início da execução do programa, o algoritmo implementado realiza aprendizado de forma contínua durante sua operação, tal que a cada iteração de controle ocorre a atualização dos pesos por meio de um gradiente simplificado e também ocorre o recálculo do erro normalizado, definido como a subtração da tensão de referência pela tensão do circuito e divisão posterior pela tensão máxima de operação do circuito.

De forma a realizar comparações entre os diferentes controladores, foram considerados ensaios em condições nominais com resposta a degrau de referência com conversor na configuração original, variação dos parâmetros do circuito, especialmente pela alteração do indutor utilizado pelo sistema e variações na tensão de referência utilizada pelo sistema. Para a validação e acompanhamento dos dados de operação do sistema desenvolvido para o microcontrolador *LAUNCHXL F28379D*, presente na Figura 04, foi desenvolvida uma plataforma *Web* utilizando o computador de placa única *BeagleBone Green*, referente à Figura 05.




Figura 04 - microcontrolador LAUNCHXL F28379D

Fonte: Texas Instruments^[08]




Figura 05 - computador de placa única *BeagleBone Green*

Fonte: SeeedStudio^[09]

Resultados e discussão

Os resultados obtidos a partir dos experimentos propostos permitiram comparar diretamente o desempenho do controlador PI e do controlador baseado em RNA no conversor *buck*. Para garantir consistência durante os testes, foi padronizada uma tensão de entrada igual a 8,0 V e uma tensão de referência igual a 6,0 V, além de inicialmente o circuito possuir um capacitor medido em 22 μ F e um indutor medido em 30 mH. Estando em sua configuração inicial, a bancada de testes

“Do conhecimento acadêmico à transformação sustentável: inovação com validação científica”

pode ser vista pela Figura 06, e posteriormente, foi adotada a bancada representada pela Figura 07, onde o valor do indutor é reduzido pela metade.




Figura 06 - bancada com componentes nominais
Fonte: autoria própria




Figura 07 - bancada com indutor reduzido
Fonte: autoria própria

Na condição nominal, o controlador PI apresentou resposta rápida, com aproximadamente 600 ms de tempo de acomodação e erro em regime permanente próximo a zero, conforme esperado e representado pela Figura 08.




Figura 08 - visor do osciloscópio de teste com controlador PI após estabilização na tensão de referência
Fonte: autoria própria

O controlador neural, por sua vez, exibiu um comportamento igualmente estável porém com uma resposta mais lenta, demandando aproximadamente 1000 ms para atingir a referência, conforme demonstrado pela Figura 09. Isto pode ser explicado pela dinâmica inerente ao processo de aprendizado em

tempo de execução, ajustando os pesos da rede ao longo das iterações de forma gradual. Apesar dessa diferença, foi possível observar que a RNA conseguiu alcançar níveis de estabilidade e precisão próximos ao controlador clássico, validando sua aplicabilidade em sistemas de potência.




Figura 09 - visor do osciloscópio de teste com controlador neural após estabilização na tensão de referência
Fonte: autoria própria

Na condição com variação dos parâmetros do circuito, onde houve a redução do indutor pela metade, a diferença entre as técnicas se mostrou evidente. Enquanto o controlador PI exigiria uma nova sintonia dos parâmetros K_p e K_i para manter o desempenho do sistema, o controlador neural foi capaz de adaptar-se automaticamente ao novo sistema, preservando a regulação da tensão de saída, conforme demonstrado pela Figura 10.




Figura 10 - visor do osciloscópio de teste com controlador neural com indutor reduzido após estabilização na tensão de referência
Fonte: autoria própria

Além disso, outro aspecto relevante da pesquisa foi o desenvolvimento da plataforma *Web* para monitoramento em tempo real do circuito, possibilitando observar de forma prática o comportamento do conversor durante os experimentos, notado pela Figura 11. A interface possibilitou a visualização se o circuito está ligado, a tensão de referência, a tensão do circuito, a corrente do circuito, há quanto tempo o circuito está em operação, o horário em que os dados foram recebidos e

“Do conhecimento acadêmico à transformação sustentável: inovação com validação científica”

o horário em que os dados foram inseridos.

The screenshot shows a web interface with two main data tables. The top table is titled 'Circuit Data' and has columns for 'Parameter' and 'Value'. The bottom table is titled 'Recent Data' and has columns for 'Circuit No.', 'Control Mode', 'Input Voltage', 'Output Voltage', 'Output Current', 'Conversion Rate', 'Sampling Time', and 'Sampling Error'.

Circuit Data	
Parameter	Value
PI	0.01
Circuit Mode	OFF
Control Voltage	5 V
Control Current	0 mA
Circuit Name	08/08/24
Inserted Time	2025/08/21, 08:12:35
Updated Time	2025/08/21, 08:12:35

Recent Data						
Circuit No.	Control Mode	Input Voltage	Output Voltage	Output Current	Conversion Rate	Sampling Time
486	OFF	5.00 V	5.00 V	0.00 mA	0.0000	2025-08-21, 08:12:32
482	ON	5.70 V	5.70 V	40.00 mA	0.0001	2025-08-21, 08:12:34
480	ON	5.70 V	5.70 V	40.00 mA	0.0000	2025-08-21, 08:12:34
480	ON	5.00 V	5.00 V	100.00 mA	0.0001	2025-08-21, 08:12:31
480	ON	5.00 V	5.00 V	90.00 mA	0.0000	2025-08-21, 08:12:32
486	ON	5.70 V	5.70 V	100.00 mA	0.0001	2025-08-21, 08:12:35
486	ON	5.70 V	5.70 V	100.00 mA	0.0000	2025-08-21, 08:12:35
487	ON	5.70 V	5.70 V	100.00 mA	0.0000	2025-08-21, 08:12:37
486	ON	5.70 V	5.70 V	100.00 mA	0.0000	2025-08-21, 08:12:37
486	OFF	0.00 V	0.00 V	0.00 mA	0.0000	2025-08-21, 08:12:31

Figura 11 - plataforma *Web* com informações do sistema
Fonte: autoria própria

Em termos gerais, os resultados demonstram que, embora o controlador PI ainda apresenta vantagens em rapidez de resposta sob condições estáveis, a rede neural é capaz de oferecer desempenho semelhante e, principalmente, maior adaptabilidade. Essa característica torna o método promissor para aplicações onde a variabilidade de componentes ou condições de operação podem dificultar o uso de controladores clássicos.

Conclusões

A pesquisa realizada permitiu demonstrar a viabilidade da aplicação de redes neurais artificiais no controle de conversores DC-DC do tipo *buck*. Apesar de apresentarem resposta mais lenta em comparação ao controlador clássico, as redes neurais mostraram-se capazes de manter estabilidade e regulação adequada da tensão de saída, tanto em condições nominais quanto diante de alterações nos parâmetros do circuito.

O teste prático de redução do indutor evidenciou que a capacidade de adaptação automática em relação ao circuito se torna a principal contribuição desta abordagem. Enquanto o controlador PI necessitaria de uma nova sintonia dos parâmetros de controle, a rede neural foi capaz de se ajustar em tempo de execução.

Outro ponto de destaque foi a integração da plataforma *Web* de monitoramento. A plataforma permitiu o acompanhamento em tempo real, proporcionando maior confiabilidade e transparência ao processo de validação, além do acompanhamento remoto da aplicação.

Portanto, pode-se concluir que o uso de redes neurais em controladores para conversores DC-DC representa uma alternativa sólida em relação às técnicas clássicas. Como colaborações futuras, sugere-se a exploração de arquiteturas neurais mais complexas, estratégias de aprendizado híbrido e ainda estratégias

com apenas aprendizado prévio.

Agradecimentos

Agradeço imensamente a Universidade Federal de Itajubá, e ao Conselho Nacional de Desenvolvimento Científico e Tecnológico, que forneceram todo o suporte necessário para a realização desta pesquisa e também ao meu orientador Robson Bauwelz Gonzatti pelos conselhos e orientações durante o período da pesquisa.

Referências

- [01] KASSAKIAN, John G.; SCHLECHT, Martin F.; VERGHESE, George C. Principles of power electronics. Reading, MA: Addison-Wesley, 1991. Acesso em: 24 de Agosto de 2025.
- [02] JAHAN, S. et al. An overview of artificial intelligence applications for power electronics. CPSS Transactions on Power Electronics and Applications, v. 7, n. 1, p. 1-16, mar. 2022. DOI: 10.24295/CPSSPEA.2022.00001. Acesso em: 24 de Agosto de 2025.
- [03] VERDE, Gabriel; AGUILAR, Carlos; AGUAYO, Jesus; DE LEÓN ALDACO, Susana. Comparación de la corriente de salida del convertidor Buck 1 vs 5 fases. 2021. Acesso em: 24 de Agosto de 2025.
- [04] LATHI, B. P. Sinais e Sistemas Lineares. 2. ed. Porto Alegre: Bookman, 2006. Acesso em: 24 de Agosto de 2025.
- [05] EMBARCADOS. Embarcados, 2025. Disponível em: <<https://www.embarcados.com.br>>. Acesso em: 24 de Agosto de 2025.
- [06] CARVALHO, André Carlos Ponce de Leon Ferreira de. Redes Neurais Artificiais. São Carlos: ICMC-USP, [s.d.]. Disponível em: <<https://sites.icmc.usp.br/andre/research/neural/>>. Acesso em: 24 de Agosto de 2025.
- [07] HAYKIN, Simon. Redes neurais: princípios e prática. Porto Alegre: Bookman Editora, 2001. ISBN 9788577800865. Disponível em: <https://books.google.com.br/books?id=bhMwDwAAQBAJ>
- [08] TEXAS INSTRUMENTS. Texas Instruments, 2025. Disponível em: <<https://www.ti.com>>. Acesso em: 24 de Agosto de 2025.
- [09] SEEDSTUDIO. SeeedStudio, 2025. Disponível em: <<http://www.seeedstudio.com/>>. Acesso em: 24 de Agosto de 2025.