



UNIVERSIDADE FEDERAL DE SANTA CATARINA  
CENTRO TECNOLÓGICO DE JOINVILLE  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE SISTEMAS ELETRÔNICOS

Carlúcio Pereira da Silva

**Redes Neurais Artificiais Aplicadas ao Controle de um Retificador Buck PFC  
Monofásico**

DEFESA DE MESTRADO

Joinville  
2024

Carlúcio Pereira da Silva

**Redes Neurais Artificiais Aplicadas ao Controle de um Retificador Buck PFC  
Monofásico**

Defesa submetida ao Programa de Pós-Graduação em Engenharia de Sistemas Eletrônicos da Universidade Federal de Santa Catarina para a obtenção do título de Mestre em Engenharia de Sistemas Eletrônicos.  
Orientador: Prof. Diego Santos Greff, Dr.

Joinville  
2024

Ficha catalográfica gerada por meio de sistema automatizado gerenciado pela BU/UFSC.  
Dados inseridos pelo próprio autor.

Pereira da Silva, Carlúcio  
Redes Neurais Artificiais Aplicadas ao Controle de um  
Retificador Buck PFC Monofásico / Carlúcio Pereira da  
Silva ; orientador, Diego Santos Greef, 2024.  
129 p.

Dissertação (mestrado) - Universidade Federal de Santa  
Catarina, Campus Joinville, Programa de Pós-Graduação em  
Engenharia de Sistemas Eletrônicos, Joinville, 2024.

Inclui referências.

1. Engenharia de Sistemas Eletrônicos. 2. Conversor CA  
CC. 3. Controlador Preditivo. 4. Conversor Buck. 5. Rede  
Neural Artificial. I. Santos Greef, Diego . II.  
Universidade Federal de Santa Catarina. Programa de Pós  
Graduação em Engenharia de Sistemas Eletrônicos. III. Título.

Carlúcio Pereira da Silva

**Redes Neurais Artificiais Aplicadas ao Controle de um Retificador Buck PFC  
Monofásico**

O presente trabalho em nível de Mestrado foi avaliado e aprovado por banca examinadora composta pelos seguintes membros:

Prof. Ademir Nied, Dr.  
Universidade do Estado de Santa Catarina

Prof. Carlos Henrique Illa Font, Dr.  
Universidade Tecnológica Federal do Paraná

Prof. Pablo Andretta Jaskowiak, Dr.  
Universidade Federal de Santa Catarina

Certificamos que esta é a **versão original e final** do trabalho de conclusão que foi julgado adequado para obtenção do título de Mestre em Engenharia de Sistemas Eletrônicos.

---

Prof. Lucas Weihmann, Dr.  
Coordenação do Programa

---

Prof. Diego Santos Greff, Dr.  
Orientador

Joinville, 22 de Março de 2024.



MINISTÉRIO DA EDUCAÇÃO  
UNIVERSIDADE FEDERAL DE SANTA CATARINA  
CENTRO TECNOLÓGICO DE JOINVILLE  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE SISTEMAS ELETRÔNICOS – PPGESE

**ATA DE DEFESA DE DISSERTAÇÃO DE MESTRADO**

Aos vinte e dois dias do mês de março de dois mil e vinte e quatro, às 9 horas, reuniu-se através de videoconferência e na sala U155 do Centro Tecnológico de Joinville da UFSC a Banca Examinadora de Dissertação de Mestrado composta pelos seguintes membros:

Nome	Instituição	Função
Prof. Dr. Diego Santos Greff	Universidade Federal de Santa Catarina	Presidente
Prof. Dr. Pablo Andretta Jaskowiak	Universidade Federal de Santa Catarina	Membro interno
Prof. Dr. Ademir Nied	Universidade do Estado de Santa Catarina	Membro externo
Prof. Dr. Carlos Henrique Illa Font	Universidade Tecnológica Federal do Paraná	Membro externo

para a avaliação da defesa do trabalho do(a) estudante **Carlúcio Pereira da Silva**, regularmente matriculado(a) sob o número 202003982, orientado(a) pelo(a) Prof. Dr. Diego Santos Greff, com trabalho intitulado **"Redes Neurais Artificiais Aplicadas ao Controle de um Retificador Buck PFC Monofásico"**. Na avaliação da Banca Examinadora, o estudante foi considerado:

APROVADO

REPROVADO

Nestes termos, assinam o estudante e os membros da Banca Examinadora:



Documento assinado digitalmente  
**Diego Santos Greff**  
Data: 04/04/2024 11:31:10-0300  
CPF: \*\*\*.266.630-\*\*  
Verifique as assinaturas em <https://v.ufsc.br>

Presidente da Banca Examinador

Membro externo



Documento assinado digitalmente  
**PABLO ANDRETTA JASKOWIAK**  
Data: 02/04/2024 12:36:55-0300  
CPF: \*\*\*.115.189-\*\*  
Verifique as assinaturas em <https://v.ufsc.br>

Membro interno

Documento assinado digitalmente  
**gov.br** **CARLOS HENRIQUE ILLA FONT**  
Data: 27/03/2024 13:35:33-0300  
Verifique em <https://validar.iti.gov.br>

Membro externo



Documento assinado digitalmente  
**CARLUCIO PEREIRA DA SILVA**  
Data: 04/04/2024 16:47:01-0300  
CPF: \*\*\*.614.001-\*\*  
Verifique as assinaturas em <https://v.ufsc.br>

Estudante

Este trabalho é dedicado à minha família, aos meus amigos e à todas as pessoas que contribuíram de alguma forma para que eu alcançasse o título de mestre, em especial à minha esposa e filhos.

## AGRADECIMENTOS

Primeiramente a Deus, o qual me agraciou com paz, saúde, serenidade e, em especial, com longanimidade durante o meu trajeto pelo mestrado.

A minha esposa Carla Carolina, que passou por duas gravidezes gemelares durante o período do mestrado. No início da pesquisa grávida dos gêmeos Benjamim e Júlia, no final grávida dos gêmeos Asafe e Ester, sempre gerando condições para eu continuar me dedicando aos estudos.

Aos meus pais, em especial a minha mãe, pelo apoio e incentivo.

Ao meu sogro pela ajuda no desenvolvimento dos filtros indutivos.

A minha filha Maria Eduarda, pelo carinho e apoio.

A equipe de apoio, que muitas vezes deixaram seus afazeres para ajudar com as crianças e proporcionar um ambiente para que eu pudesse dedicar aos estudos, um obrigado especial para minha sogra e tia Regina.

Ao meu amigo dos tempos de graduação Luiz Fernando M. Arruda, mestre pela Universidade Federal de Santa Catarina - Joinville, pelas horas dedicadas às releituras dessa dissertação bem como as sugestões pontuais e precisas.

À todos os meus professores, desta e de outras instituições de ensino, os quais contribuíram para o meu desenvolvimento e crescimento intelectual.

Ao meu orientador, professor Dr. Diego Santos Greff, especialmente pela paciência, também não poderia deixar de citar, o aprendizado, as sugestões e correções no decorrer da minha passagem pelo PPGESE.

A todos que de forma direta ou indireta contribuíram para concepção desta dissertação.

Ao povo brasileiro, por meio da Capes, contribuiu financeiramente em parte desta pesquisa.

*"Combati o bom combate, completei a carreira e guardei a fé."  
(2 Timóteo 4:7)*

## RESUMO

Este trabalho apresenta um estudo sobre a utilização de algoritmos baseados em redes neurais artificiais aplicadas ao controle da tensão de saída e correção de fator de potência de um retificador Buck, que deu origem a um *Adaptive Neural Network Controller* (ANNC), o qual emprega as técnicas *Feedforward Current* do indutor de saída e neurônio aditivo, onde a ação de controle se dá por meio da razão cíclica aplicada ao acionamento do transistor de potência. O aprendizado aplicado ao ANNC possui característica de tempo real, sem a necessidade de treinamento prévio portanto, o sistema se adapta as mudanças regulando a tensão e corrigindo o fator de potência instantaneamente. A simulação do ANNC utilizou o *software* PSIM, onde são analisadas as respostas dinâmicas do retificador Buck frente ao degrau na potência de saída e seus efeitos quanto: a estabilidade da tensão na carga, a manutenção do fator de potência praticamente unitário, e o baixo conteúdo harmônico da corrente de entrada. Neste trabalho são apresentados os resultados de simulação e experimental, onde é possível observar que as técnicas empregadas, *Feedforward Current* e neurônio aditivo, promovem o ajuste da tensão de saída conforme a referência e mantém um fator de potência praticamente unitário. No intuito de comprovar a aplicação da técnica apresentada, um protótipo de 1500W, 220V de tensão de entrada, e até 60V de tensão de saída foi implementado, onde foram obtidos resultados de acordo com o intervalo dos ensaios realizados, alcançando um fator de potência de 0,9932 com uma Distorção Harmônica Total na ordem de 5,94%.

**Palavras-chave:** Conversor CA-CC, Controlador Neural, Controlador Preditivo, Rede Neural Artificial, Conversor *Buck* PFC.

## ABSTRACT

This work brings a study on the use of algorithms based in artificial neural networks applied to the control of output voltage and power factor correction of a buck rectifier, spawning an Adaptive Neural Network Controller (ANNC), which employs the Feedforward Current techniques of the output inductor and additive neuron, where control action is exerted through the duty cycle applied to the triggering of the power switch gate. The learning applied to ANNC features real-time characteristics, devoid of the need for prior training, thus the system adapts to changes by regulating voltage and instantly correcting power factor. The simulation of ANNC is conducted by the PSIM software, wherein the dynamic responses of the buck rectifier to output power step and its effects on load voltage stability, maintaining virtually unity power factor, and low harmonic content of input current are analyzed. This work presents simulation and experimental results, where it can be observed that the employed techniques, Feedforward Current and additive neuron, facilitate adjustment of output voltage as per reference and maintain a virtually unity power factor. In a bid to validate the presented technique, a prototype of 1500W, 220V input voltage, and up to 60V output voltage was implemented, yielding results within the range of conducted tests, achieving a power factor of 0.9932 with a Total Harmonic Distortion on the order of 5.94%.

**Keywords:** AC-DC Converter, Neural Controller, Predictive Controller, Artificial Neural Network, PFC Buck Converter.

## LISTA DE FIGURAS

Figura 1 – Relação entre potência e energia de diversas tecnologias de baterias. . . . .	21
Figura 2 – Diagrama esquemático das principais topologias de retificadores Buck e Boost monofásicos viáveis à PFC. . . . .	23
Figura 3 – Diagrama esquemático das principais topologias clássicas de retificadores Buck e Boost trifásicos viáveis à PFC. . . . .	24
Figura 4 – Retificador Buck trifásico formado por três braços monofásicos viável à PFC.	25
Figura 5 – Retificador Buck trifásico bridgeless viável à PFC. . . . .	25
Figura 6 – Sistema dinâmico desconhecido. . . . .	26
Figura 7 – Arquitetura simplificada para o Buck PFC proposto. . . . .	28
Figura 8 – Aspectos funcionais de um neurônio biológico. . . . .	30
Figura 9 – Modelo não-linear de um neurônio. . . . .	31
Figura 10 – Exemplo de aprendizagem por correção de erro e supervisionada por um professor. . . . .	34
Figura 11 – Algoritmo referente a RNA com aprendizado supervisionado por correção de erro. . . . .	38
Figura 12 – RNA monocamada com apenas um nó de processamento. . . . .	38
Figura 13 – RNA multicamada com $m$ nós sensoriais na camada de entrada, 3 nós de processamento na camada oculta e apenas 1 nó de processamento na camada de saída. . . . .	39
Figura 14 – RNA com aprendizado supervisionado e atualização dos pesos por correção de erro modelada para um neurônio aditivo. . . . .	40
Figura 15 – Conversor Buck. . . . .	42
Figura 16 – Etapa de operação onde o conversor encontra-se com a chave fechada. . .	43
Figura 17 – Etapa de operação onde o conversor encontra-se com a chave aberta. . . .	43
Figura 18 – Gráfico da tensão e da corrente sobre o indutor $L$ . Também se observa o comportamento da corrente sobre $C$ na medida que $V_L$ varia. . . . .	44
Figura 19 – Principais formas de onda para o conversor operando no limite da condução contínua. . . . .	45
Figura 20 – Retificador Buck PFC monofásico. . . . .	46
Figura 21 – Estágios de operação do retificador Buck PFC para a chave fechada. . . . .	47
Figura 22 – Estágio de operação do retificador Buck PFC para a chave aberta. . . . .	47
Figura 23 – Retificador Buck com PFC em Modo de Condução Descontínua. . . . .	48
Figura 24 – Formas de onda para um retificador Buck idealizado. . . . .	48
Figura 25 – Formas de onda para um retificador Buck PFC modulado via PWM com frequência fixa sem controle para o PFC, com indutor de saída de 15 $mH$ . Os demais parâmetros podem ser observados na Tabela 3. . . . .	49

Figura 26 – Formas de onda para um retificador Buck PFC modulado via PWM com frequência fixa e estratégia <i>feedforward Current</i> para correção do PFC, com indutor de saída da 15 mH. Os demais parâmetros podem ser observados na Tabela 3. . . . .	49
Figura 27 – Diagrama da estratégia de controle para o Buck PFC baseada na malha fechada da corrente do indutor de saída. . . . .	50
Figura 28 – Diagrama de blocos da estrutura de potência e de controle baseada em rede neural para o retificador Buck PFC. . . . .	51
Figura 29 – Princípio do neurônio aditivo aplicado à camada de saída do sistema neural de controle sugerido para o ANNC. As variáveis $x_1, \dots, x_m$ , para uma RNA multicamada, representam a saída da camada oculta anterior a camada de saída, e para uma RNA monocamada, representam os estímulos de entrada da rede neural. . . . .	53
Figura 30 – Configuração do ANNC para a RNA Monocamada. . . . .	54
Figura 31 – Atraso entre $V_m$ e $I_{L_o}$ para o primeiro semi-ciclo de $V_{ac}$ . $V_{R_o}$ e $I_{L_o}$ encontram-se normalizados no intervalo [0 1]. . . . .	56
Figura 32 – Alteração na razão cíclica modulante no primeiro semi-ciclo de $V_{ac}$ devido a falta de referência para o ANNC a partir $V_{R_o}$ . . . . .	56
Figura 33 – Fator de correção de 0.4 aplicado a $V_m$ para o primeiro ciclo de $V_{ac}$ . Valor médio de $D$ atua no ajuste da amplitude de $V_m$ . A característica ondulatório de $D$ aplica deformação na forma do sinal de $V_m$ para corrigir $I_{ac}$ implicando num FP próximo da unidade. $V_o$ encontra-se normalizado no intervalo [0 1]. . . . .	57
Figura 34 – Algoritmo referente ao ANNC. Onde se lê $x_j w_{kj}$ , corresponde aos parâmetros anteriores a camada de saída. . . . .	58
Figura 35 – Resposta do ANNC com taxa de aprendizado fixa. ANNC não consegue corrigir o erro, $D_{erro}$ , ao longo de todo o período de processamento e, portanto, a Energia do Erro apresenta oscilações acentuadas. Destaca-se a legenda com amostra entre 0 e 100 ms. $V_o$ e $I_o$ encontram-se normalizados no intervalo [0 1]. . . . .	59
Figura 36 – Resposta do ANNC com taxa de aprendizado dinâmica, com utilização do algoritmo RMSProp gerando a mesma taxa de aprendizado tanto para o <i>bias</i> quanto para os demais pesos da rede. ANNC apresenta instabilidade entre 220 e 680 ms e não consegue corrigir o erro, $D_{erro}$ , durante essa fatia do processamento e, portanto, a Energia do Erro apresenta oscilações. Destaca-se a legenda com amostra entre 350 e 450 ms. $V_o$ e $I_o$ encontram-se normalizados no intervalo [0 1]. . . . .	60

Figura 37 – Resposta do ANNC com taxa de aprendizado dinâmica. Utilização do algoritmo RMSProp com taxa de aprendizado individualizada para o <i>bias</i> . Não se observa oscilações nos parâmetros do ANNC e nem nos do Buck. Destaca-se a legenda com amostra entre 0 e 100 ms. $V_o$ e $I_o$ encontram-se normalizados no intervalo [0 1]. . . . .	61
Figura 38 – Evolução das taxas de aprendizado para o <i>bias</i> e os demais pesos da rede para a arquitetura monocamada. . . . .	63
Figura 39 – Evolução das taxas de aprendizado para o <i>bias</i> e os demais pesos da rede para a arquitetura MLP com três neurônios na camada oculta. . . . .	63
Figura 40 – Evolução das taxas de aprendizado para o <i>bias</i> e os demais pesos da rede para a arquitetura MLP com cinco neurônios na camada oculta. . . . .	64
Figura 41 – Resposta do ANNC monocamada para o cenário em que são comparadas as atualizações das razões cíclicas a partir das funções de ativação Logística e ELU. . . . .	65
Figura 42 – Reflexo da atualização da razão cíclica $D$ sobre $V_m$ e $V_o$ considerando as funções de ativação Logística de ELU. $V_o$ encontra-se normalizada no intervalo [0 1]. . . . .	66
Figura 43 – Atualização da razão cíclica, $D$ , reverbera negativamente na forma da corrente de entrada, $I_{ac}$ , para as funções de ativação Logística e ELU. . . . .	67
Figura 44 – Análise de qualidade do fator preditivo para as funções Logística e ELU. . . . .	68
Figura 45 – Arquiteturas propostas para o ANNC. . . . .	69
Figura 46 – Ondulação da corrente sobre $L_o$ . . . . .	71
Figura 47 – Relação entre o índice de modulação, $M$ , e duas outras grandezas, o ângulo, $\theta$ , e a ondulação relativa da corrente de saída, $\Delta I_{or}$ . . . . .	72
Figura 48 – Filtro anti-aliasing . . . . .	75
Figura 49 – Amostragem da corrente de entrada . . . . .	76
Figura 50 – Amostragem da tensão de entrada . . . . .	76
Figura 51 – Amostragem da Corrente de Saída . . . . .	77
Figura 52 – Detector de passagem por zero . . . . .	77
Figura 53 – Diagrama esquemático <i>snubber</i> não-dissipativo . . . . .	78
Figura 54 – Kit de desenvolvimento NUCLEO-L491RG . . . . .	79
Figura 55 – Diagrama do Buck PFC proposto. . . . .	80
Figura 56 – Resposta do ANNC sem as características do neurônio aditivo e da técnica <i>feedforward current</i> . ANNC encontra-se configurado com função de ativação ELU e taxa de aprendizado individualizada para o <i>bias</i> definida pelo algoritmo RMSProp. Intervalo de análise de 0 a 1000 ms. Potência de saída de 800 W. $V_o$ , $I_o$ e $V_{ref}$ da Figura 56(b) encontram-se normalizados no intervalo [0 1]. . . . .	81

Figura 57 – ANNC no controle de $V_o$ e $I_o$ a partir do ajuste na variação de $V_m$ . Resposta para uma carga de 800 W com indutor de saída de 18 mH. $V_{ref}$ , $V_o$ e $V_e$ encontram-se normalizados no intervalo [0 1]. . . . .	82
Figura 58 – Gráfico da tensão e da corrente de entrada, $V_{ac}$ e $I_{ac}$ para um FP = 0,99277. Resposta para uma carga de 800 W com indutor de saída de 18 mH. . . . .	83
Figura 59 – Gráficos da tensão e da corrente de saída, $V_o$ e $I_o$ , para o ANNC com RNA Monocamada. Resposta para uma carga de 800 W com indutor de saída de 18 mH. . . . .	84
Figura 60 – Resposta do ANNC ao degrau em $V_{ref}$ , com indutor de saída de 18 mH. $V_o$ , $I_o$ e $V_{ref}$ encontram-se normalizados no intervalo [0 1]. . . . .	85
Figura 61 – Atualização de $V_m$ frente a variação em $P_o$ alternando entre 800 e 1500 watts com indutor de saída de 18 mH. $V_o$ , $I_o$ e $V_{ref}$ encontram-se normalizados no intervalo [0 1]. . . . .	86
Figura 62 – Espectro harmônico da corrente de entrada. Resposta para uma carga de 800 W com indutor de saída de 18 mH. . . . .	86
Figura 63 – Vista superior do protótipo . . . . .	89
Figura 64 – Vistas frontal e traseira do sistema de potência e dos módulos para o condicionamento dos sinais do protótipo. . . . .	89
Figura 65 – Vistas de $L_f$ e $L_o$ . . . . .	90
Figura 66 – Vista superior da resistência de carga. Potência máxima de 6800W em 220V. . . . .	90
Figura 67 – Amostragem e sincronismo. <b>CH1</b> : Pulso de sincronismo com 66 $\mu s$ , <b>CH2</b> : Processamento ADC com intervalo de 12.4 $\mu s$ e <b>CH3</b> : Intervalo de processamento do ANNC. . . . .	92
Figura 68 – Sincronismo do ADC com o PWM. <b>CH1</b> : Pulso de sincronismo com 66 $\mu s$ , <b>CH2</b> : Amostragem do ADC a cada 66 $\mu s$ e <b>CH3</b> : Período do PWM em 33 $\mu s$ . . . . .	93
Figura 69 – Gráfico da tensão e da corrente de saída, $V_o$ e $I_o$ , como resposta do ANNC frente a inicialização para uma carga de 525 W. Para melhor visualização da magnitude dos dados, $V_o$ encontra-se deslocada por um <i>offset</i> de -20 V e $I_o$ em -20 A. <b>CH3</b> : $I_o$ e <b>CH4</b> : $V_o$ . . . . .	93
Figura 70 – Conversor Buck PFC operando tal qual preconiza a técnica <i>Feedforward Current</i> , $I_{L_o}$ acima do valor absoluto de $I_{ac}$ . $V_m$ encontra-se deslocado de um <i>offset</i> de -1.5 V. Os sinais de $V_{ac}$ , $I_{ac}$ e $I_{L_o}$ estão sem deslocamento por <i>offset</i> . Conversor sujeito a uma carga de 306 W e $V_o$ igual a 36,20 V. <b>CH1</b> : $V_{ac}$ , <b>CH2</b> : $I_{ac}$ , <b>CH3</b> : $I_{L_o}$ e <b>CH4</b> : $V_m$ . . . . .	94
Figura 71 – Gráfico da tensão e da corrente de entrada, $V_{ac}$ e $I_{ac}$ , alvos para o cálculo do fator de potência em resposta à cargas de 306 W e 700 W para $V_o$ a 36,20 V. . . . .	95

Figura 72 – Resposta do ANNC para uma carga de 1050 W e FP com magnitude igual a 0,9917 com $V_o$ igual a 60 V. $V_m$ encontra-se deslocado de um <i>offset</i> de -2,4 V. Os sinais de $V_{ac}$ , $I_{ac}$ e $I_{L_o}$ estão sem deslocamento por <i>offset</i> . <b>CH1</b> : $V_{ac}$ , <b>CH2</b> : $I_{ac}$ , <b>CH3</b> : $I_{L_o}$ e <b>CH4</b> : $V_m$ .. . . . .	96
Figura 73 – Espectro harmônico da corrente de entrada lida pelo osciloscópio para uma carga de 306 W e $V_o$ com magnitude igual a 36,20 V. . . . .	96
Figura 74 – Espectro harmônico da corrente de entrada numericamente processada com os dados utilizados na geração do gráfico da Figura 73. . . . .	97
Figura 75 – Resposta do ANNC ao degrau em $V_{ref}$ . Na Figura 75(a) $V_m$ encontra-se deslocado por um <i>offset</i> de -1.5 mV, $V_o$ e $I_{L_o}$ não encontram-se deslocados por <i>offset</i> . Na Figura 75(b), tem-se $V_{ac}$ e $I_{ac}$ sem deslocamento por <i>offset</i> . Conversor sujeito a variação em $P_o$ entre 306 W e 370 W. <b>CH1</b> : $V_{ac}$ , na Figura 75(a) <b>CH2</b> : $V_o$ e na Figura 75(b) <b>CH2</b> : $I_{ac}$ , <b>CH3</b> : $I_{L_o}$ e <b>CH4</b> : $V_m$ . . . . .	98
Figura 76 – Resposta do ANNC frente ao degrau em $P_o$ , alternando entre 374 W e 568 W. $V_m$ deslocado por um <i>offset</i> de -1.0 V. <b>CH2</b> : $V_o$ , <b>CH3</b> : $I_o$ e <b>CH4</b> : $V_m$ . . . . .	99
Figura 77 – Resposta do ANNC frente ao degrau em $P_o$ , alternando entre 374 W e 568 W. <b>CH1</b> : $V_{ac}$ e <b>CH2</b> : $I_{ac}$ . . . . .	100
Figura 78 – Diagrama de blocos do aproximador de funções ANNC. . . . .	112
Figura 79 – Comportamento de $D_o$ e $V_{R_o}$ frente a aproximação de $D_{o(eq)}$ para $D_{ref}$ , o que produz a aproximação de $V_o$ em relação a $V_{ref}$ . $V_{R_o}$ encontra-se normalizado no intervalo [0 1]. . . . .	116
Figura 80 – Cenário da Figura: 57. ANNC no controle de $V_o$ e $I_o$ a partir do ajuste na variação de $V_m$ . Resposta para uma carga de 800 W com indutor de saída de 18 mH. $V_{ref}$ , $V_o$ , $I_{L_o}$ , $V_e$ , $I_{C_o}$ e $I_o$ encontram-se normalizados no intervalo [0 1]. . . . .	117
Figura 81 – Cenário da Figura 58. Gráfico da tensão e da corrente de entrada, $V_{ac}$ e $I_{ac}$ para um FP = 0,99277. Resposta para uma carga de 800 W com indutor de saída de 18 mH. . . . .	117
Figura 82 – Cenário da Figura 59. Gráficos da tensão e da corrente de saída, $V_o$ e $I_o$ . Resposta para uma carga de 800 W com indutor de saída de 18 mH. . . . .	118
Figura 83 – Cenário da Figura 60. Resposta do ANNC ao degrau em $V_{ref}$ , com indutor de saída de 18 mH. $V_o$ e $I_o$ encontram-se normalizados no intervalo [0 1]. . . . .	118
Figura 84 – Cenário da Figura 61. Atualização de $V_m$ frente a variação em $P_o$ alternando entre 800 e 1500 watts com indutor de saída de 18 mH. $V_{ref}$ , $V_o$ e $I_o$ encontram-se normalizados no intervalo [0 1]. . . . .	118
Figura 85 – Núcleo Laminado de Ferro Cilício para o $L_f$ . . . . .	125
Figura 86 – Núcleo Laminado de Ferro Cilício para o $L_o$ . . . . .	127
Figura 87 – Desempenho do ANNC para o Buck PFC trifásico. . . . .	129

## LISTA DE TABELAS

Tabela 1 – Topologias para carregadores de baterias. . . . .	21
Tabela 2 – Medidas da qualidade do fator preditivo que relaciona as funções de ativação Logística e ELU associadas ao ANNC. . . . .	68
Tabela 3 – Especificações para o projeto do retificador Buck PFC. . . . .	70
Tabela 4 – Parâmetros de simulação para as RNAs. . . . .	79

## LISTA DE ABREVIATURAS E SIGLAS

CC	Corrente Contínua . . . . .	20
CA-CC	Corrente Alternada para Corrente Contínua . . . . .	20
VEs	Veículos Elétricos . . . . .	20
SAE	<i>Society of Automotive Engineering</i> . . . . .	21
IEEE	<i>Institue of Electrical and Eletronics Engineers</i> . . . . .	22
IEC	<i>International Electrotechinal Commission</i> . . . . .	22
PFC	<i>Power Factor Correction</i> . . . . .	22
PWM	<i>Pulse Width Modulation</i> . . . . .	22
FP	<i>Fator de Potência</i> . . . . .	22
DHT	Distorção Harmônica Total . . . . .	22
PID	Proporcionais Integrais Derivativos . . . . .	25
RNAs	Redes Neurais Artificiais . . . . .	27
ANNC	<i>Adaptive Neural Network Controller</i> . . . . .	27
ELU	Exponential Linear Unit . . . . .	33
LMS	<i>Least Mean Square</i> . . . . .	35
GLMS	<i>Generalized Least Mean Square</i> . . . . .	35
MIT	<i>Massachusetts Institute of Technology</i> . . . . .	36
RDG	Regra Delta Generalizada . . . . .	36
MLP	<i>Multilayer Perceptron</i> . . . . .	39
MCC	Modo de Condução Contínua . . . . .	48
PLL	<i>Phase Lock Loop</i> . . . . .	77
DPZ	Detector de Passagem por Zero . . . . .	77
CPU	<i>Central Processing Unit</i> . . . . .	78
DMA	<i>Direct Memory Access</i> . . . . .	78
FPU	<i>Float Point Unit</i> . . . . .	78
ADC	<i>Analogue-to-Digital Converter</i> . . . . .	78
ARTR	Aprendizagem Recorrente em Tempo Real . . . . .	103
FCC	<i>Fully Connected Cascade</i> . . . . .	103

## LISTA DE SÍMBOLOS

$\hat{X}$	Representação de uma grandeza vetorial . . . . .	36
$V_o$	Tensão de saída . . . . .	42
$V_E$	Tensão contínua de entrada . . . . .	43
$t_f$	Tempo da chave fechada . . . . .	43
$t_a$	Tempo da chave aberta . . . . .	43
$V_L$	Tensão sobre o indutor . . . . .	43
$V_{ac(pico)}$	Tensão alternada de pico . . . . .	46
$I_{ac}$	Corrente alternada de entrada . . . . .	48
$V_{ac}$	Tensão alternada de entrada . . . . .	52
$V_o$	Tensão de saída . . . . .	52
$I_o$	Corrente de saída . . . . .	52
$I_{L_o}$	Corrente sobre o indutor de saída . . . . .	52
$L_o$	Indutor de saída . . . . .	52
$V_m$	Tensão modulante . . . . .	52
$R_o$	Carga conectada na saída do retificador . . . . .	52
$C_o$	Filtro capacitivo de saída . . . . .	52
$v_{R_k}$	Tensão característica sobre $R_k$ do neurônio aditivo . . . . .	52
$V_{R_o}$	Tensão de ondulação sobre $R_o$ devido $I_{L_o}$ . . . . .	52
$V_{ref}$	Tensão de referência . . . . .	54
$D_{ref}$	Razão cíclica de referência ou desejada . . . . .	54
$D_o$	Razão cíclica obtida após a ativação do neurônio . . . . .	54
$\bar{D}_o$	Razão cíclica obtida antes da ativação do neurônio . . . . .	54
$D$	Razão cíclica . . . . .	54
$D_{erro}$	Erro calculado entre $D_{ref}$ e $D_{o(eq)}$ . . . . .	54

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b>	<b>20</b>
1.1	RETIFICADORES CONTROLADOS PWM	22
1.2	REDES NEURAIS APLICADAS A CONVERSORES	26
1.3	OBJETIVOS	27
<b>1.3.1</b>	<b>Objetivo geral</b>	<b>27</b>
<b>1.3.2</b>	<b>Objetivos específicos e contribuições</b>	<b>27</b>
1.4	ESTRUTURA DO TRABALHO	28
<b>2</b>	<b>REDES NEURAIS ARTIFICIAIS: PRINCÍPIOS E APLICAÇÕES</b>	<b>30</b>
2.1	ASPECTOS GERAIS	30
2.2	FUNÇÃO DE ATIVAÇÃO	32
2.3	TAXA DE APRENDIZADO	33
2.4	APRENDIZADO DE UMA RNA	34
<b>2.4.1</b>	<b>Regra Delta</b>	<b>35</b>
<b>2.4.2</b>	<b>Regra Delta Generalizada</b>	<b>36</b>
2.5	ALGORITMO	37
2.6	ARQUITETURA MONOCAMADA	37
2.7	ARQUITETURA MULTICAMADA	38
2.8	MODELO ADITIVO DE UM NEURÔNIO	40
2.9	CONCLUSÃO	41
<b>3</b>	<b>RETIFICADORES BUCK PFC</b>	<b>42</b>
3.1	CONVERSOR BUCK CC-CC	42
<b>3.1.1</b>	<b>Etapas de Operação</b>	<b>43</b>
<b>3.1.2</b>	<b>Modelagem</b>	<b>44</b>
3.2	RETIFICADOR BUCK PFC MONOFÁSICO	46
<b>3.2.1</b>	<b>Operando como PFC</b>	<b>46</b>
<b>3.2.2</b>	<b>Controle Feedforward para o Buck PFC</b>	<b>48</b>
3.3	CONCLUSÃO	50
<b>4</b>	<b>RNA APLICADA AO RETIFICADOR BUCK</b>	<b>51</b>
4.1	ESTRATÉGIA DE CONTROLE	51
4.2	MODELAGEM DO ANNC	52
4.3	PARÂMETROS FORMAIS ASSOCIADOS AO ANNC	53
4.4	RESPOSTA DO MÉTODO	55
4.5	ANÁLISE DE DESEMPENHO	56
<b>4.5.1</b>	<b>Algoritmo</b>	<b>57</b>
<b>4.5.2</b>	<b>Taxa de Aprendizado Dinâmica como Fator de Desempenho</b>	<b>57</b>
<b>4.5.3</b>	<b>Taxa de Aprendizado Dinâmica Independente Aplicada a RNA Multicamada</b>	<b>60</b>

4.5.4	<b>Influência do Número de Neurônios na Taxa de Aprendizado Dinâmica</b>	<b>62</b>
4.6	INFLUÊNCIA DA FUNÇÃO DE ATIVAÇÃO NO DESEMPENHO . . . . .	62
4.7	MÉTRICAS DE DESEMPENHO DAS FUNÇÕES DE ATIVAÇÃO . . . . .	64
4.8	ARQUITETURA DAS RNAS APLICADAS AO ANNC . . . . .	68
4.9	CONCLUSÃO . . . . .	69
<b>5</b>	<b>PROJETO E SIMULAÇÃO . . . . .</b>	<b>70</b>
5.1	PROJETO E DIMENSIONAMENTO . . . . .	70
<b>5.1.1</b>	<b>Esforços nos Semicondutores . . . . .</b>	<b>73</b>
<b>5.1.2</b>	<b>Condicionamento de Sinais . . . . .</b>	<b>74</b>
<b>5.1.3</b>	<b>Circuitos Auxiliares . . . . .</b>	<b>75</b>
<b>5.1.4</b>	<b>Processamento Digital . . . . .</b>	<b>78</b>
5.2	PARÂMETROS DO SISTEMA PARA AS SIMULAÇÕES . . . . .	79
5.3	RESULTADOS DAS SIMULAÇÕES . . . . .	79
<b>5.3.1</b>	<b>Operação sem as Técnicas <i>Feedforward Current</i> e Neurônio Aditivo</b>	<b>80</b>
<b>5.3.2</b>	<b>Operação com as Técnicas <i>Feedforward Current</i> e Neurônio Aditivo</b>	<b>82</b>
5.4	CONCLUSÃO . . . . .	87
<b>6</b>	<b>RESULTADOS EXPERIMENTAIS . . . . .</b>	<b>88</b>
6.1	PROTÓTIPO . . . . .	88
6.2	PARAMETRIZAÇÃO . . . . .	91
6.3	RESULTADOS . . . . .	92
6.4	CONCLUSÃO . . . . .	101
<b>7</b>	<b>CONCLUSÃO E TRABALHOS FUTUROS . . . . .</b>	<b>102</b>
7.1	TRABALHOS FUTUROS . . . . .	102
	<b>REFERÊNCIAS . . . . .</b>	<b>104</b>
	<b>APÊNDICE A – COMPROVAÇÃO DO MÉTODO . . . . .</b>	<b>110</b>
A.1	O ANNC COMO APROXIMADOR DE FUNÇÕES . . . . .	110
A.2	VALIDAÇÃO DE $V_{R_o}$ COMO ATRIBUTO DE UM NEURÔNIO ADITIVO PARA O ANNC . . . . .	112
	<b>APÊNDICE B – RESULTADOS DO BUCK PFC PARA A RNA MLP . . . . .</b>	<b>117</b>
	<b>APÊNDICE C – CÓDIGO FONTE DAS RNAS ASSOCIADAS AO ANNC . . . . .</b>	<b>119</b>
	<b>APÊNDICE D – PROJETO FÍSICO DOS INDUTORES . . . . .</b>	<b>124</b>
D.1	CÁLCULO DO INDUTOR DE ENTRADA $L_f$ . . . . .	124
D.2	CÁLCULO DO INDUTOR DE SAÍDA $L_o$ . . . . .	126
	<b>APÊNDICE E – BUCK PFC TRIFÁSICO . . . . .</b>	<b>129</b>

## 1 INTRODUÇÃO

As fontes de alimentação em Corrente Contínua (CC) são amplamente empregadas com o objetivo de processar energia elétrica para equipamentos eletroeletrônicos, como notebooks, equipamentos hospitalares, dispositivos industriais, bem como para veículos elétricos e produtos aeroespaciais (SAADATMAND *et al.*, 2020). Entre os requisitos das fontes de tensão CC diante de uma carga é regular tensão ou corrente e proporcionar a estabilidade destas frente a variações de tensão e de corrente. Os conversores Corrente Alternada para Corrente Contínua (CA-CC), também conhecidos como retificadores, especialmente os controlados, são frequentemente utilizados para melhorar os requisitos das fontes, como estabilidade da tensão e da corrente na carga.

Nos últimos tempos o crescimento do mercado de Veículos Elétricos (VEs) tem aumentado a demanda por carregadores de baterias. O destaque dado pela Agency (2019) para os veículos elétricos, mostra a importância destes no cenário mundial, os quais representam uma contrapartida frente aos veículos com motores à combustão. Para tal destaca-se benefícios como, segurança, eficiência energética, redução da poluição do ar atmosférico e também da sonora, o que promove, a cada ano, a ampliação do alcance desse tipo de veículo.

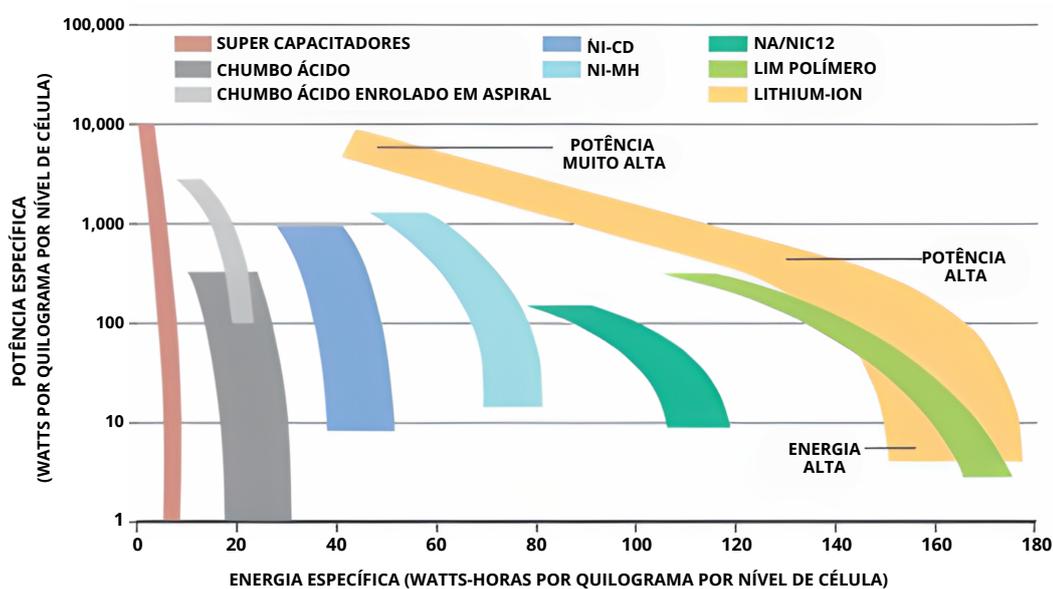
Com a ampliação da procura por VEs, na mesma proporção, houve um desdobramento na demanda por sistemas com alta disponibilidade de armazenamento de energia como, por exemplo, células a combustível, supercapacitores, baterias, etc. Dentre os sistemas de armazenamento de energia as baterias, especialmente devido as características como, densidade de energia, escalabilidade e segurança, as tornam a principal fonte de energia para sistemas que envolvem mobilidade.

De acordo com Rosolem (2016) as principais tecnologias de baterias recarregáveis em operação comercial na atualidade constam das baterias de Chumbo-Ácido (LEAD ACID), Níquel-Cádmio (Ni-Cd), Hidretos metálicos de níquel (Ni-MH) e Íon-Lítio (LITHIUM-ION), bem como suas variantes. A Figura 1 apresenta uma comparação entre a potência e a energia específica de cada uma das principais tecnologias de baterias, com destaque para as baterias de Íon-Lítio.

Segundo Rosolem (2016), as características positivas que corroboram para o destaque das baterias de Íon-Lítio constam da segurança, elevada densidade de energia, suporta elevados picos de corrente, excelente desempenho em ciclagem, tempo de recarga, alta eficiência de carga e baixo custo na manutenção. Porém, vale ressaltar o aspecto negativo que ainda afeta sua utilização generalizada, o qual representa sua principal desvantagem, a sensibilidade para com a temperatura, o que impacta diretamente na segurança e tempo de recarga.

De acordo com Joos *et al.* (2010), ao considerar o trabalho de Dickerman e Harrison (2010) contextualizado segundo a *Society of Automotive Engineering* (SAE), têm-se a classificação das topologias para carregadores de baterias divididas em pelo menos três categorias, conforme a Tabela 1. As categorias I e II são do tipo internas nos veículos, onde a categoria I

Figura 1 – Relação entre potência e energia de diversas tecnologias de baterias.



Fonte: Johnson Controls: Adaptado de (ROSOLEM, 2016)

considera tensões de entrada na ordem de 110 a 240 Vac limitados a 15 A, e a categoria II considera apenas entradas de 220 a 240 Vac limitados a 60 A, sendo carregadores trifásicos e/ou monofásicos. Por sua vez, a categoria III trata de carregadores externos aos veículos e são do tipo trifásicos.

Tabela 1 – Topologias para carregadores de baterias.

Nível	Utilização	Potência	Tempo de Carga	Característica
I	Residencial	Até 3,3 kW	De 4 até 11 horas	Carga Lenta
II	Público/Privado	Até 14,4 kW	Até 3 horas	Carga Normal
III	Estação Pública	Até 240 kW	Até 30 minutos	Carga Rápida

Fonte: Adaptado de (JOOS *et al.*, 2010; DICKERMAN; HARRISON, 2010)

De acordo com Dacol *et al.* (2019) os carregadores de baterias encontram-se divididos em dois grupos, os com estágio único e os com dois estágios. Os carregadores com apenas um estágio, geralmente, são dedicados para manutenção de baixas potências. Já os carregadores de dois estágios são considerados quando a exigência de potência é maior. No caso das topologias com estágio duplo, apresentam para o primeiro estágio um retificador e para o segundo estágio um conversor CC-CC para adequar tensão e corrente dedicados ao controle da carga da bateria. No caso dos carregadores de dois estágios, na medida que a potência exigida para a carga das baterias avança, faz-se necessário a adição do controle de fator de potência ao sistema visando atender as normas que tratam do controle de harmônicos inseridos na rede elétrica (DACOL

*et al.*, 2019).

De acordo com Lacroix *et al.* (2010) o carregamento de baterias é a etapa mais crítica na arquitetura de veículos elétricos, haja visto os riscos envolvidos no processo de carga, como por exemplo, controle do fluxo de corrente que contribui para evitar o sobreaquecimento das baterias e possíveis danos. Diante desses aspectos, manter o estado estacionário do sistema de carregamento das baterias dentro de um limiar de erro máximo, considerando para tal a estabilidade das tensões e correntes de entrada e saída bem como o fator de potência próximo da unidade, é o desejado para o controle do sistema.

## 1.1 RETIFICADORES CONTROLADOS PWM

Segundo Lacroix *et al.* (2010), a crescente ampliação da frota de VEs implicará no aumento da inserção de componentes harmônicas no sistema de distribuição de energia elétrica, e na mesma proporção se espera a redução do fator de potência, o que valida a necessidade de conversores com características PFC (*Power Factor Correction*).

As arquiteturas com modulação *Pulse Width Modulation* (PWM) se destacam das arquiteturas clássicas de retificadores (retificadores a diodos não controlados e a tiristores controlados), devido a possibilidade de realização da correção do Fator de Potência (FP) próximo da unidade. A configuração dos retificadores controlados PWM dispõem, basicamente, de semicondutores que atuam como chaves eletrônicas de potência (BARBI; MARTINS, 2000).

As arquiteturas clássicas oferecem um custo maior para se alcançar resultados para o FP próximo à unidade quando comparadas com as arquiteturas baseadas em PWM, o que corrobora para distorções na corrente em detrimento da tensão de alimentação. De acordo com Dacol *et al.* (2019), um retificador clássico a diodos sem PFC pode provocar redução do fator de potência em 54%. A determinação do FP considera a Distorção Harmônica Total (DHT) da corrente de acordo com as Equações (1) e (2), as quais descrevem a DHT e o FP (KOLAR; FRIEDLI, 2011).

$$DHT = \frac{\sqrt{\sum_{n=2}^{\infty} I_n^2}}{I_1} \quad (1)$$

$$FP = \frac{1}{\sqrt{1 + DHT^2}} \cos(\theta) \quad (2)$$

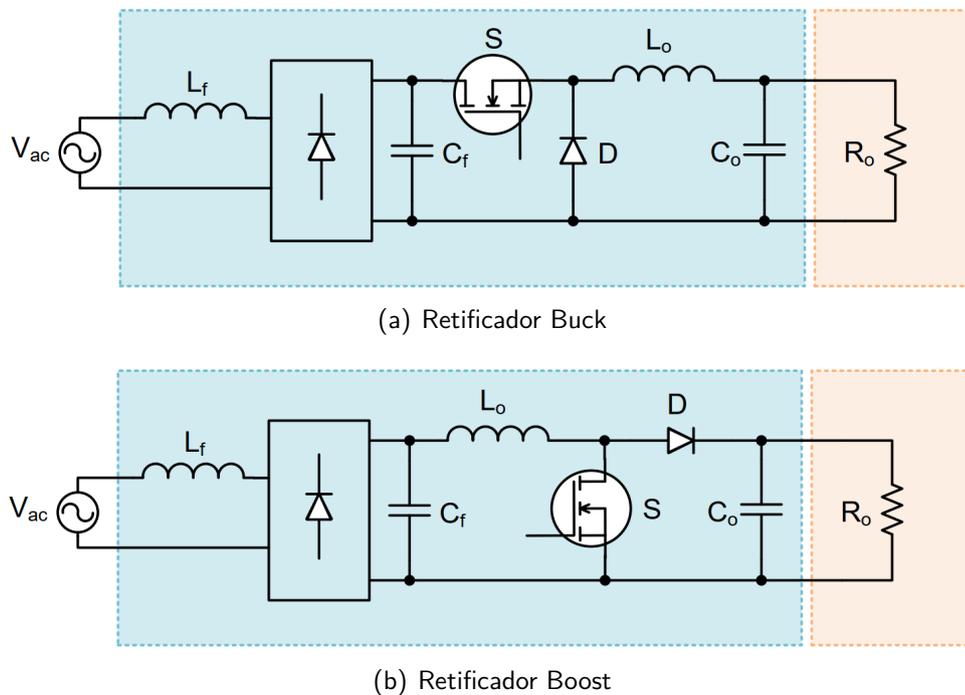
De acordo com Mohagheghi *et al.* (2009), uma questão relevante sobre projetos de eletrônica de potência são os efeitos das variações dos parâmetros dos componentes no desempenho do sistema. Portanto, na medida que alterações nas características dos componentes ocorrem, especialmente nas chaves de controle, também se observa variações significativas na resposta entregue pelo conversor à carga, o que corrobora significativamente para alterações no PFC.

Considerando as topologias que incluem modulação PWM, torna-se possível atender aos requisitos das normas IEEE 519-2022 e IEC 1000-3-2 a respeito da qualidade na forma

da corrente de entrada, especialmente quando são consideradas as harmônicas de 3ª, 5ª e 7ª ordem ao adicionar a arquitetura PFC (SPIAZZI, 1997; SOUZA, F. P.; BARBI, 1999).

Os retificadores PWM Buck, são essencialmente abaixadores de tensão, já os Boost são do tipo elevadores de tensão, na Figura 2 são apresentados os retificadores monofásicos Buck e Boost, e na Figura 3 os seus similares trifásicos, ambos viáveis à PFC. Outras duas possibilidades para um retificador trifásico Buck trata dos exemplos ilustrados nas Figuras 4 e 5, de modo que na Figura 4 apresenta-se o Buck formado por três braços monofásicos (KOLAR; FRIEDLI, 2011; GREFF, 2009). Em todas as figuras o destaque é dado para o módulo de potência, portanto, não constam dos seus diagramas de controle.

Figura 2 – Diagrama esquemático das principais topologias de retificadores Buck e Boost monofásicos viáveis à PFC.

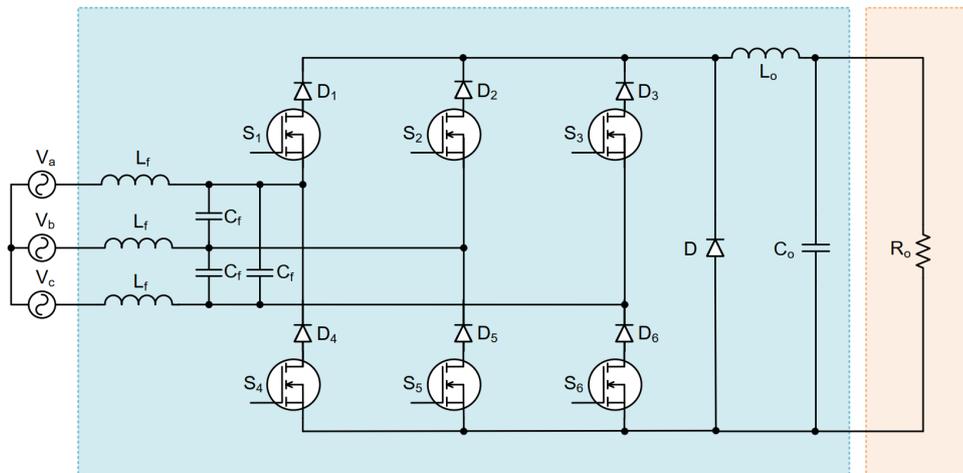


Fonte: Autoria própria.

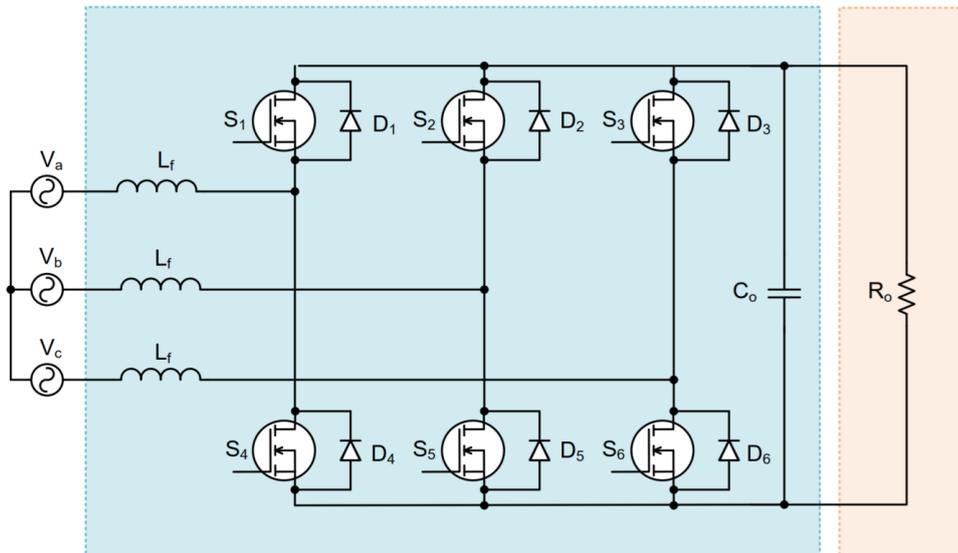
Barbi (2006) orienta a utilização de modulação PWM com modulação senoidal uma vez que o controle de corrente por razão cíclica fixa introduz harmônicos de corrente, e Pomilio (2007) relata a importância da frequência fixa na geração do sinal PWM para se evitar corrente nula. Portanto, desde que se pondere os efeitos do controle PWM em frequência fixa em relação aos harmônicos de corrente, como salientado por Barbi (2006) e Pomilio (2007), estes retificadores apresentam características que os credenciam como soluções de retificação e filtragem para atender a demanda de sistemas de corrente contínua bem como as normas para controle da qualidade da energia para a rede elétrica.

Dentre as diversas topologias de retificadores PFC destaca-se as características dos retificadores Buck em contrapartida aos Boost, como a capacidade de obter baixa tensão CC de saída, alta eficiência, proteção contra curto-circuito e a redução da corrente de surto na

Figura 3 – Diagrama esquemático das principais topologias clássicas de retificadores Buck e Boost trifásicos viáveis à PFC.



(a) Retificador Buck.



(b) Retificador Boost

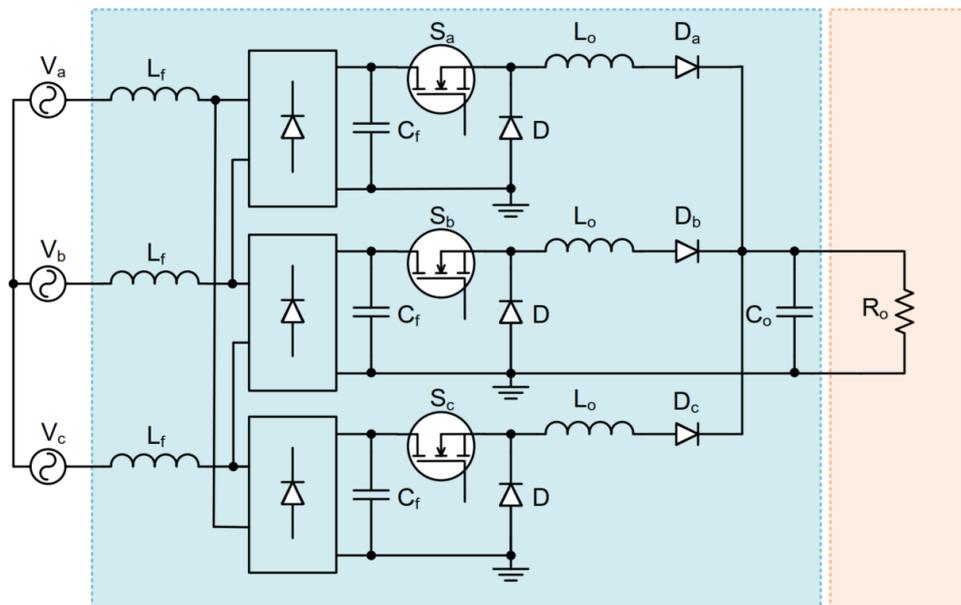
Fonte: Autoria própria.

inicialização, o que pode ser observado nos estudos propostos por Hirachi *et al.* (1995) e F Pottker Souza e Barbi (1999), no que diz respeito aos sistemas monofásicos, bem como em Greff (2009), no que tange aos sistemas trifásicos.

Para os retificadores monofásicos PFC, destaca-se os trabalhos apresentados por F Pottker Souza e Barbi (1999) e Hirachi *et al.* (1995), onde se observa elevado ganho para o fator de potência. Em F Pottker Souza e Barbi (1999), o controle do FP é baseado na realimentação da corrente do indutor de saída, já em Hirachi *et al.* (1995) o controle é feito ajustando a amplitude da portadora do sinal PWM de controle.

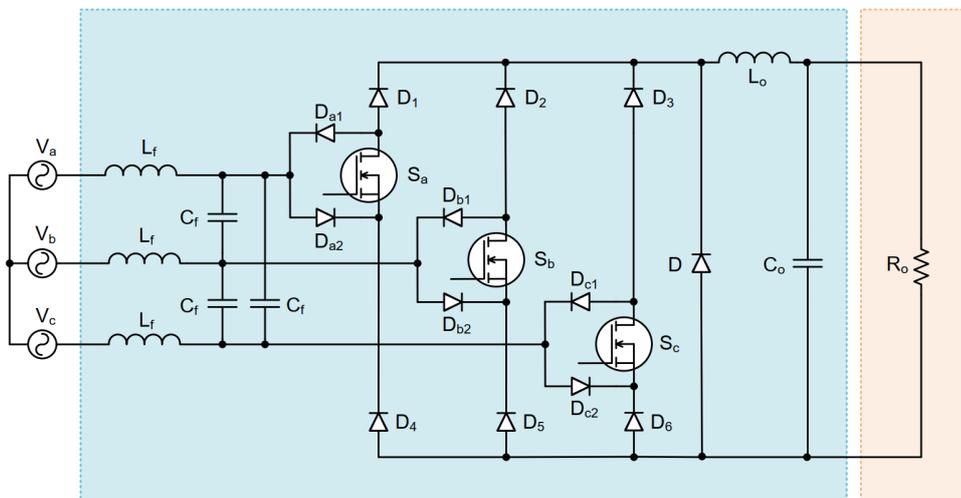
Considerando os retificadores trifásicos PFC, em Greff (2009), o destaque é dado à técnica de controle do Buck, a qual trata-se da modelagem por espaço-de-estados do retificador,

Figura 4 – Retificador Buck trifásico formado por três braços monofásicos viável à PFC.



Fonte: Autoria própria

Figura 5 – Retificador Buck trifásico bridgeless viável à PFC.



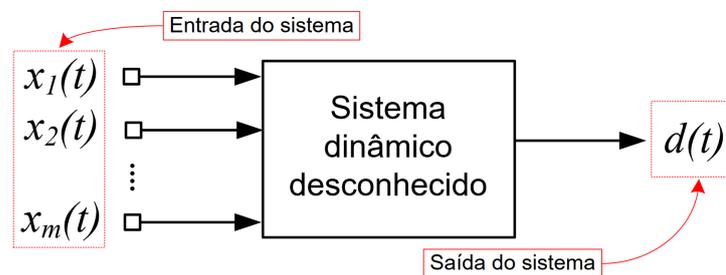
Fonte: Autoria própria

onde salienta-se o controle contínuo do sistema a partir das coordenadas  $dq$  obtidas de acordo com a transformada Clarke/Park. O autor determina a operação do sistema sob o prisma de dois compensadores PID (Proporcional Integral Derivativo), um para a componente de corrente direta e outro para a componente de quadratura. De acordo com os resultados apresentados, o sistema mostrou-se robusto e confiável, especialmente no que tange ao PFC. O protótipo desenvolvido pelo autor tem como o base o retificador visto na Figura 5.

## 1.2 REDES NEURAI APLICADAS A CONVERSORES

Um sistema dinâmico com definição matemática desconhecida, também conhecidos por "caixa preta", é apresentado na Figura 6 com o objetivo de sistematizar a generalidade que o controle por meio de redes neurais pode alcançar. Para tal considera-se que toda a informação sobre o sistema está contida na relação dos dados de entrada em detrimento dos dados de saída em instantes discretos de tempo. Quando um estímulo  $x_m(t)$  ( $m$  o número de entradas no tempo  $t$ ) é aplicado a partir dos diversos nós da entrada do sistema, este responde produzindo uma saída desejada  $d(t)$ , que representa a variável de controle do sistema (HAYKIN, 2001).

Figura 6 – Sistema dinâmico desconhecido.



Fonte: Adaptado de (HAYKIN, 2001)

Inerente ao modo como estes sistemas operam, apresentam forte característica de não-linearidade em sua resposta, fazendo-se necessário um modelo de controle que proporcione alto desempenho na dinâmica de resposta do sistema (UTOMO *et al.*, 2011). De acordo com Oviedo *et al.* (2006), a utilização de controladores clássicos, ainda que muito eficientes e vastamente aplicados, faz da busca por um sistema com elevado grau de precisão especialmente trabalhosa, dada a grande quantidade de cálculos matemáticos necessários para corrigir tais não-linearidades, as quais se apresentam nas incertezas dos parâmetros físicos e na dinâmica do sistema, diferentemente do que ocorre com o controle baseado em dados. Este fenômeno amplia-se quando o projeto dos controladores envolvem os retificadores trifásicos.

Não é recente a utilização de técnicas de otimização baseadas em algoritmos inteligentes aplicadas em eletrônica de potência, como exemplo têm-se os estudos observados em Maddaleno (1994) bem como em Fang Lin Luo e Ye (1999), onde os autores fazem uso de redes neurais como sistemas de controle para conversores CC-CC. Outros inúmeros estudos podem ser avaliados, e uma breve amostra pode ser encontrada em Kurokawa *et al.* (2011), Maruta *et al.* (2012) e Nizami e Mahanta (2014).

A utilização de redes neurais em eletrônica de potência se destaca por apresentar recursos para lidar com ruídos e incertezas. O Perceptron desenvolvido por Silva *et al.* (2021) para o controle do conversor CC-CC Buck, o Perceptron proposto Silva *et al.* (2021) como controlador para o conversor Boost CC-CC, bem como o trabalho apresentado por Arruda *et al.* (2020) pelos estudos do conversor Ćuk aplicado ao rastreamento do ponto de máxima

potência de módulos fotovoltaicos utilizando redes neurais, são exemplos de redes neurais aplicadas à eletrônica de potência como controladores. O Perceptron multicamada observado em Mohagheghi *et al.* (2009), empregado no mapeamento entrada versus saída de um retificador *full-bridge* a diodos, não representa um controlador, no entanto, propõe um sistema de supervisão que avalia o desempenho do circuito eletrônico de potência com o objetivo de monitorar a sua eficiência.

### 1.3 OBJETIVOS

O surgimento de microcontroladores com alta capacidade de processamento com custos mais acessíveis, tem promovido as investigações dos controladores baseados em Redes Neurais Artificiais (RNAs), como o *Adaptive Neural Network Controller* (ANNC), objeto de estudo dessa dissertação. Em detrimento aos controladores clássicos, com o objetivo de oferecer uma contrapartida à tomada de decisão diante da necessidade de controle de grandezas não-lineares, considera-se para este trabalho a implementação do ANNC aplicado ao controle de um retificador Buck por meio de um *hardware* dedicado.

#### 1.3.1 OBJETIVO GERAL

Desenvolver e aplicar um controlador com base em RNA ao retificador Buck PFC monofásico, a fim de melhorar a resposta dinâmica, compensar as não idealidades e desenvolver um sistema com desempenho de igual a superior ao apresentado pelos métodos de controle clássico. Propõe-se para o controlador a utilização de uma RNA com aprendizagem supervisionada e por correção do erro.

#### 1.3.2 OBJETIVOS ESPECÍFICOS E CONTRIBUIÇÕES

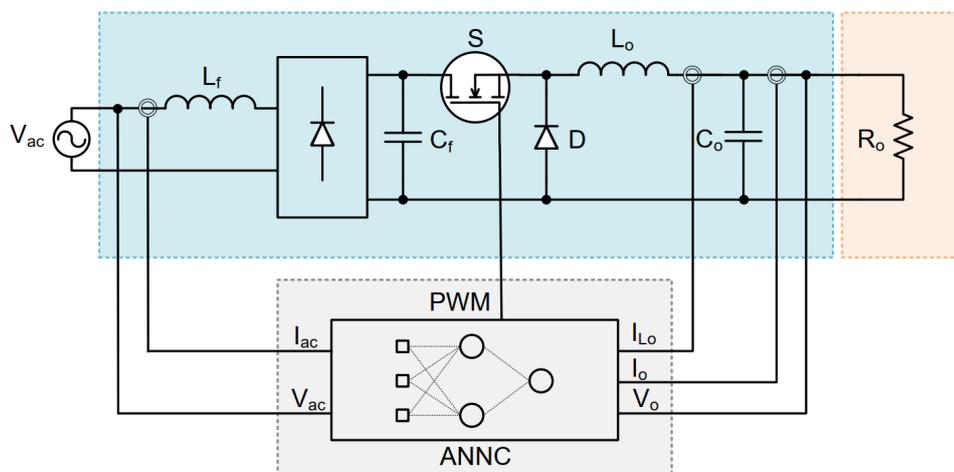
O projeto desenvolvido neste estudo envolve alguns pontos específicos, contribuições, dos quais destaca-se devido a sua relevância:

1. Analisar e estudar duas arquiteturas de RNAs para o ANNC no controle do estágio retificador, uma RNA monocamada e uma multicamada.
2. Aplicar o controle *Feedforward Current* por RNA.
3. Introduzir o neurônio aditivo como instrumento para a estrutura de controle no contexto da eletrônica de potência.
4. Estudar os aspectos temporais promovidos pelo neurônio aditivo à técnica *Feedforward Current* no controle do Buck PFC.
5. Avaliar e estudar o desempenho do ANNC com a aplicação da taxa de aprendizado dinâmica associada ao neurônio aditivo e a técnica *Feedforward Current* na atualização dos pesos da rede neural.

6. A prototipagem de um retificador Buck PFC como ilustrado na Figura 7, onde são apresentadas a topologia e o sistema de controle propostos com as seguintes premissas:

- Manter tensão de saída do estágio retificador dentro do limiar especificado pela referência.
- Corrigir a diferença de fase entre a corrente e a tensão de entrada do retificador.
- Reduzir a distorção harmônica na corrente de entrada.

Figura 7 – Arquitetura simplificada para o Buck PFC proposto.



Fonte: Autoria própria.

## 1.4 ESTRUTURA DO TRABALHO

A organização deste estudo trata do uso da inteligência computacional aplicada aos conversores eletrônicos de potência, onde entende-se como conversores eletrônicos de potência os conversores CA-CC, especificamente o conversor Buck PFC, está desenvolvida em seis capítulos conforme descrito abaixo:

O Capítulo 1 trata dos conceitos introdutórios, onde foram expostos a contextualização do problema, uma breve releitura das topologias utilizadas nos carregadores de baterias para VEs e também a topologia a ser estudada no contexto desta dissertação.

O capítulo 2 são apresentadas algumas das principais arquiteturas de RNAs e também o neurônio aditivo, que exerce papel de destaque no sistema de controle proposto.

No capítulo 3 é apresentada a modelagem da topologia para o conversor Buck que será desenvolvida neste estudo, o Buck PFC monofásico. Neste capítulo também serão avaliados os aspectos do dimensionamento do circuito de potência do conversor.

O capítulo 4 apresenta a metodologia de controle para o Buck PFC, a qual encontra-se pautada em RNAs.

No capítulo 5 demonstra-se os resultados obtidos para o controlador. A priori apresenta-se as simulações idealizadas para a solução pretendida para este estudo.

O capítulo 6 traz os resultados experimentais, os quais tem o objetivo de confrontar o que se obteve com as simulações numéricas.

E o capítulo 7 faz o fechamento do estudo em questão com apontamentos para melhorias e aprimoramentos para o ANNC.

## 2 REDES NEURAIS ARTIFICIAIS: PRINCÍPIOS E APLICAÇÕES

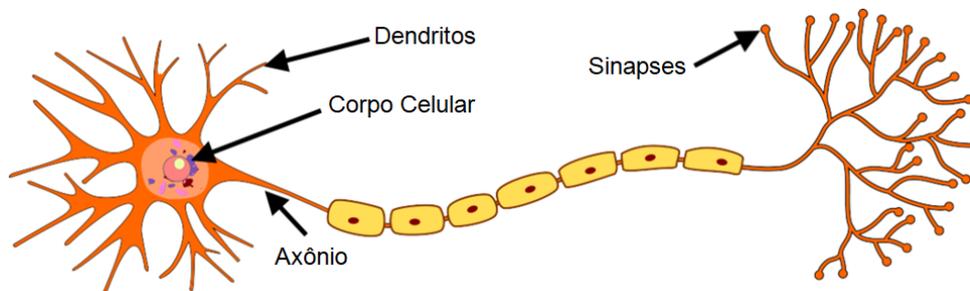
Neste capítulo serão apresentadas as características gerais tanto do neurônio biológico quanto do neurônio artificial. A descrição sobre os atributos e as particularidades do modelo neuronal proponente deste estudo, por exemplo, taxa de aprendizado dinâmica, regras de aprendizado, características de um neurônio aditivo, etc, também serão desenvolvidas neste capítulo.

### 2.1 ASPECTOS GERAIS

As duas características mais marcantes de uma rede neural artificial são a sua capacidade de generalização e de processamento paralelo. O processamento paralelo é devido a distribuição da sua estrutura de processamento. Já a generalização está associada ao fato de um neurônio artificial ser capaz de produzir saídas adequadas para entradas ainda não observadas pela rede. A associação de tais características tornam possível a solução de problemas complexos que não possuem algoritmos conhecidos (HAYKIN, 2001).

A estrutura fundamental de uma rede neural é baseada no cérebro, de sorte que a Figura 8 apresenta as principais características de um neurônio biológico, as quais são abstraídos pelo modelo artificial.

Figura 8 – Aspectos funcionais de um neurônio biológico.



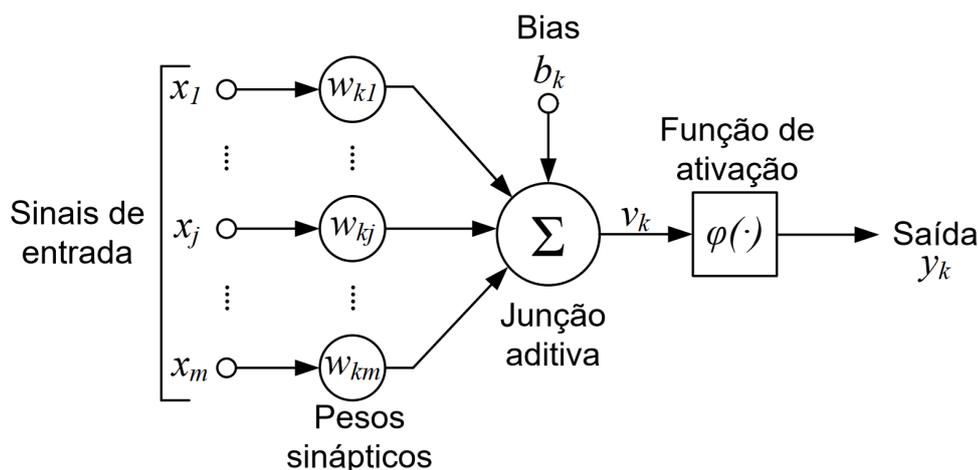
Fonte: Adaptado de (Wikimedia Commons)

Como pode ser observado na Figura 8, um neurônio biológico encontra-se dividido em pelo menos quatro partes principais: os Dendritos que são responsáveis por captar os impulsos advindos de outros neurônios, direcionando-os para o núcleo celular para processamento; o corpo celular responsável pelo processamento e assim tomar a decisão de geração ou não de sinal de saída; axônio, este é responsável por conduzir o estímulo gerado pelo Corpo Celular até as Sinapses; e as Sinapses que representam as estruturas de conexão entre a saída de um neurônio e a entrada de outro.

O primeiro estudo que consta da modelagem matemática de um neurônio artificial em detrimento de um neurônio artificial foi desenvolvido por McCulloch e Pitts (1943). Outro

cientista que desenvolveu o primeiro trabalho sobre aprendizado, denominado como aprendizagem auto-organizada, foi Hebb (1949), o qual representa um marco na história dos estudos sobre redes neurais. Tais trabalhos serviram de base para os estudos dirigidos por Rosenblatt (1958), o qual desencadeou uma técnica de aprendizado extremamente utilizada no contexto da redes neurais, o aprendizado supervisionado.

Figura 9 – Modelo não-linear de um neurônio.



Fonte: Adaptado de (HAYKIN, 2001)

A arquitetura de um neurônio artificial pode ser avaliada na Figura 9, a qual representa a base do modelo neuronal proposto por Rosenblatt (1958), conhecido na literatura como Perceptron. Tal modelo trata de um conjunto de sinapses, também conhecidos como elos de ligação, onde se observa um sinal  $x_j$  na entrada da sinapse  $j$ , a qual encontra-se conectada ao neurônio  $k$ , onde a sinapse  $j$  encontra-se multiplicada pelo peso sináptico  $w_{kj}$ , como evidenciado pelos dendritos apresentados no neurônio biológico da Figura 8.

Com relação a trajetória do sinal de entrada  $x_j$  aplicado na entrada do neurônio  $k$ , após o processamento das sinapses, observa-se uma junção aditiva que tem a função de somar as entradas ponderadas pelos devidos pesos sinápticos, como ocorre no neurônio biológico por meio do Corpo Celular. Após o somatório ponderado, têm-se a ativação do neurônio a partir da função de ativação, a qual restringe o sinal na saída, semelhante ao papel do Axônio na ativação do neurônio biológico.

O modelo neuronal da Figura 9 inclui o bias,  $b_k$ , que é o peso sináptico relativo a entrada com valor fixo da rede e que tem a função de aplicar uma transformação afim ao combinador linear. Dessa forma o potencial de ativação da rede fica submetido ao direcionamento dado pelo bias, onde este não possui referência direta com o modelo biológico.

As entradas do neurônio artificial são identificadas por  $x_1, x_2, \dots, x_m$ , os pesos por  $w_{k1}, w_{k2}, \dots, w_{km}$  e  $x_m$  a  $m$ -ésima entrada do neurônio. Considerando o bias como uma entrada independente do neurônio, o resultado do combinador linear,  $u_k$ , será

$$u_k = \sum_{j=1}^m w_{kj}x_j \quad (3)$$

Dessa forma o potencial de ativação,  $v_k$ , ou seja, a saída da junção aditiva, fica sendo

$$v_k = u_k + b_k \quad (4)$$

Sem perda de generalidade, associando  $b_k$  com a entrada de menor ordem da rede,  $x_0$  assumindo a entrada fixa relativa ao bias, possibilita, a partir das Equações (3) e (4), a atualização do combinador linear,  $v_k$ , para

$$v_k = \sum_{j=0}^m w_{kj}x_j \quad (5)$$

O sinal de saída,  $y_k$ , encontra-se sujeito a função de ativação  $\varphi(\cdot)$ , que representa a ativação do neurônio, a qual recebe como parâmetro de entrada a saída do combinador linear, portanto

$$y_k = \varphi(v_k) \quad (6)$$

A descrição dos aspectos funcionais do neurônio artificial, exceto pelo bias, quando comparado com o neurônio biológico, ficam evidentes ao considerar o modelo apresentado na Figura 8 em relação aquela da Figura 9.

## 2.2 FUNÇÃO DE ATIVAÇÃO

A característica marcante de uma função de ativação deve ser a sua não-linearidade suave, ou seja, ser diferenciável em qualquer ponto, o que não se observa no Perceptron desenvolvido por Rosenblatt (1958), que apresenta uma limitação abrupta. A função de ativação utilizada no Perceptron é conhecida na literatura como limitar ou *Heaviside* e pode ser expressa de acordo com a Equação (7) (HAYKIN, 2001).

$$y_k = \begin{cases} 1, & \text{if } v_k \geq 0 \\ 0, & \text{if } v_k < 0 \end{cases} \quad (7)$$

Por outro lado tem-se a clássica função logística que cumpre com o requisito de não-linearidade suave, a qual encontra-se representada nas Equações (8a) e (8b), nessa ordem, denotam a função e sua derivada, de forma que  $a > 0$ .

$$\text{Logística} = \begin{cases} \varphi(v_k(n)) = \frac{1}{1+\exp(-av_k(n))} & (8a) \\ \varphi'(v_k(n)) = \frac{a\exp(-av_k(n))}{[1+\exp(-av_k(n))]^2} & (8b) \end{cases}$$

Outra função clássica como função de ativação e que apresenta características de não-linearidade sigmoide é a tangente hiperbólica, que na sua forma geral encontra-se definida nas Equações (9a) e (9b), tanto para a função propriamente dita quanto para a sua derivada, onde  $(a, b) > 0$ . Na realidade a função tangente hiperbólica é a função logística reescalada (HAYKIN, 2001).

$$\text{Tangente Hiperbólica} = \begin{cases} \varphi(v_k(n)) = \left\{ a \tanh(bv_k(n)) \right. & (9a) \\ \varphi'(v_k(n)) = \left\{ \frac{b}{a} [a - y_k(n)] [a + y_k(n)] \right. & (9b) \end{cases}$$

A função de ativação *Exponential Linear Unit* (ELU), proposta por Clevert *et al.* (2015), frente a normalização dos dados não é tão crítica quanto, por exemplo, a função logística ou tangente hiperbólica, portanto, a função de ativação,  $\varphi_k(\cdot)$ , considerada para este estudo trata de uma ELU, onde  $\varphi'_k(\cdot)$  é a sua derivada, e  $\alpha$  é o ajuste da sua inclinação, a qual encontra-se nas Equações (10a) e (10b), onde a (10b) constitui a sua derivada.

$$\text{ELU} = \begin{cases} \varphi_k(v_k)(n) = \begin{cases} v_k, & \text{if } v_k > 0 \\ \alpha(\exp^{v_k} - 1), & \text{if } v_k \leq 0 \end{cases} & (10a) \\ \varphi'_k(v_k)(n) = \begin{cases} 1, & \text{if } v_k > 0 \\ \varphi_k(v_k) + \alpha, & \text{if } v_k \leq 0 \end{cases} & (10b) \end{cases}$$

As orientações dos autores para a função ELU, como valor inicial para a inclinação da função, pode ser conferido na Tabela 4.

### 2.3 TAXA DE APRENDIZADO

A taxa de aprendizado, ou passo de aprendizagem, trata de um valor constante e positivo que define a velocidade do aprendizado. Se o valor for muito pequeno o algoritmo convergirá lentamente, caso seja muito alto este pode produzir oscilações o que corrobora para a não convergência. O critério para escolha do valor da taxa de aprendizado é crítico num projeto envolvendo redes neurais. Diante disso discute-se dois mecanismos capazes de influenciar positivamente na velocidade de convergência do aprendizado de um sistema neuronal artificial, o *Momentum* e o algoritmo RMSProp.

O termo *Momentum*, de acordo com Rumelhart *et al.* (1986), pode acelerar a convergência da rede em detrimento ao erro e promover um nível de aprendizado mais estável. Contudo, de acordo com Zhi-Quan Luo (1991), a taxa de aprendizado dinâmica tem a capacidade de substituir o *Momentum*.

A indicação à substituição do *Momentum* pela taxa de aprendizado dinâmica, especificamente pelo algoritmo RMSProp, trata da característica deste em seguir as constantes alterações na superfície do erro ao longo de uma única dimensão de peso, o que não se observa

no *Momentum* (HAYKIN, 2001; LUO, Z.-Q., 1991). O RMSProp proposto por Tieleman, Hinton *et al.* (2012) tem contribuído para ampliar as arquiteturas dos algoritmos de otimização, os trabalhos de Reddy *et al.* (2018), Zaheer *et al.* (2018) e De *et al.* (2018) são exemplos a esse respeito.

O algoritmo RMSProp atualiza dinamicamente a taxa de aprendizado  $\eta$ . Para tal considera a média móvel,  $E$ , dos quadrados dos gradientes anteriores,  $[\delta^2]_{(n-1)}$ , no processo de atualização da taxa de aprendizado, de tal forma que a média móvel é definida pela Equação (11), onde  $E[\delta^2]_n$  representa a média móvel dos quadrados dos gradientes e  $\beta$  um termo de ajuste do algoritmo.

$$E[\delta^2]_n = \beta \cdot E[\delta^2]_{(n-1)} + (1.0 - \beta) \cdot \delta_n^2 \quad (11)$$

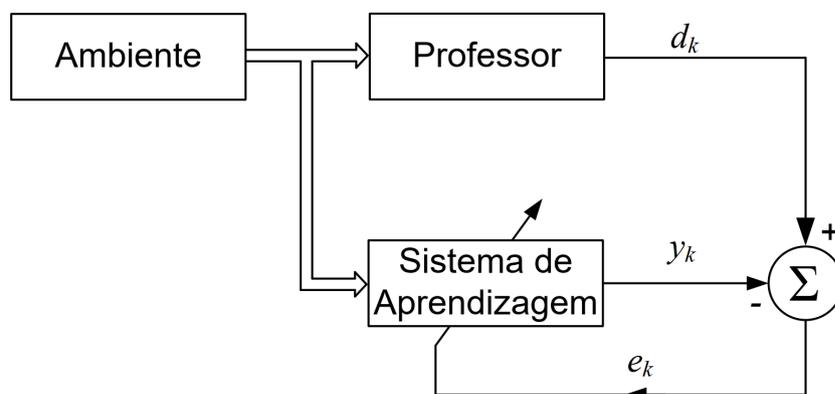
Já a taxa de aprendizado  $\eta_{(n)}$ , sujeita ao algoritmo RMSProp, tem sua atualização pela Equação (12), onde  $\epsilon$  representa um valor pré-definido com o objetivo de evitar divisão por zero. Os valores iniciais para os parâmetros do algoritmo RMSProp, conforme indicado por Tieleman, Hinton *et al.* (2012), constam na Tabela 4.

$$\eta_{(n)} = \frac{\eta_{(n-1)}}{\sqrt{E[\delta^2]_n + \epsilon}} \quad (12)$$

## 2.4 APRENDIZADO DE UMA RNA

Existem vários meios para que o processo de aprendizagem de uma rede neural ocorra, por exemplo, Baseada em Memória, Hebbiana, Competitiva, de Boltzmann, por Atribuição de Crédito, Supervisionada, por Correção de Erro, dentre outras. Neste contexto, apenas as técnicas de aprendizagem por Correção de Erro e Supervisionada fazem parte do escopo deste trabalho.

Figura 10 – Exemplo de aprendizagem por correção de erro e supervisionada por um professor.



Fonte: Adaptado de (HAYKIN, 2001)

O sinal de saída, representado por  $y_k$ , para o exemplo da Figura 10, trata de uma única saída do neurônio, onde este é comparado com  $d_k$  que representa a resposta desejada do sistema, ou simplesmente saída desejada. A comparação entre  $y_k$  e  $d_k$  produz um sinal de erro representado por  $e_k$  na Equação (13) (WIDROW *et al.*, 1975). A descrição apresentada neste parágrafo corresponde ao bloco "Sistema de Aprendizagem" visto na Figura (10).

$$e_k(n) = d_k(n) - y_k(n) \quad (13)$$

A supervisão do aprendizado fica a cargo da entidade "Professor" observada na Figura (10). O professor tem conhecimento do ambiente e a rede neural não. O conhecimento que o professor tem a respeito do ambiente é representado na forma de amostras discretas que relacionam entrada-saída e encontram-se dispostas em um conjunto de exemplos.

Como o professor tem conhecimento prévio do ambiente, então é capaz de fornecer à rede neural a resposta adequada para uma dada amostra do conjunto de exemplos, onde se entende como saída adequada a relação  $d_k - y_k$  que leva a  $e_k$  nulo. Dessa forma o professor conduz o treinamento do neurônio iterativamente até que se alcance a condição de parada, a qual culmina com a atualização dos pesos de modo que a rede possa emular o papel do professor. Na medida que o algoritmo alcança o critério de parada o professor pode ser dispensado e a rede neural passa a lidar com o ambiente independente da supervisão do professor (HAYKIN, 2001).

Existem vários mecanismos para se definir o aprendizado, e diversos algoritmos para atualização dos pesos constam na literatura, dentre os quais destaca-se o algoritmo *Least Mean Square* (LMS) e o *Generalized Least Mean Square* (GLMS), discutidos individualmente nas Seções 2.4.1 e 2.4.2 a seguir.

### 2.4.1 REGRA DELTA

O algoritmo LMS, também conhecido como algoritmo do Mínimo Quadrado Médio ou Regra Delta, foi apresentado inicialmente por Widrow *et al.* (1975). Posteriormente o LMS foi ampliado para uso em filtros adaptativos, onde o laço de realimentação em torno de  $\hat{w}$  faz o algoritmo se comportar como um filtro passa-baixas (WIDROW; HOFF, 1960). O LMS define um mecanismo para a atualização dos pesos a partir da energia instantânea do erro  $\varepsilon(n)$ . A energia instantânea do erro, Equação (14), representa a função de custo ou nível de desempenho, que tem como objetivo definir o quão próximo o valor de  $y_k$  está de  $d_k$  a partir de  $e_k$  (HAYKIN, 2001).

$$\varepsilon(n) = \frac{1}{2} e_k^2(n) \quad (14)$$

A energia total do erro é observada ao somar todos os termos  $\frac{1}{2} e_k^2(n)$  dos neurônios da camada de saída da rede. A Equação (15) determina a energia total do erro, onde  $C$  representa todos os neurônios da camada de saída.

$$\varepsilon_{(total)}(n) = \frac{1}{2} \sum_{j \in C} e_k^2(n) \quad (15)$$

A metodologia para o LMS pressupõe uma estimativa para o vetor gradiente a partir do vetor  $\hat{x}$  formado pelos sinais de entrada do neurônio, onde a Equação (16) representa o vetor gradiente. O sinal negativo na equação indica a descida do gradiente no espaço do vetor de pesos.

$$\hat{g}(n) = -\hat{x}_k(n)e_k(n) \quad (16)$$

Assim têm-se a atualização dos pesos da rede por meio do algoritmo LMS de acordo com a Equação (17).

$$\hat{w}(n+1) = \hat{w}(n) + \Delta\hat{w}(n) \therefore \Delta\hat{w}(n) = \eta\hat{g}(n) \quad (17)$$

Um ponto importante é que a correção dos pesos é de natureza local. O que significa que os ajustes sinápticos estão localizados no ambiente do neurônio  $k$  para um elemento excitador  $x_j$  do vetor  $\hat{x}$ . Sendo assim expressa-se a localidade de  $k$  destacando o gradiente local,  $\delta_k(n)$ , para o LMS segundo a Equação (18).

$$\delta_k(n) = x_j(n)e_k(n) \quad (18)$$

Considerando as Equações (17) e (18), supondo que  $w_{kj}(n)$  representa um elemento do vetor  $\hat{w}$  do neurônio  $k$  excitado por um elemento  $x_j$  no passo de tempo  $n$ , de acordo com o algoritmo LMS, o ajuste dado a um determinado peso sináptico pode ser redefinido para Equação (19).

$$w_{kj}(n+1) = w_{kj}(n) + \Delta w_{kj}(n) \therefore \Delta w_{kj}(n) = \eta\delta_k(n) \quad (19)$$

#### 2.4.2 REGRA DELTA GENERALIZADA

O algoritmo GLMS, também conhecido como Regra Delta Generalizada (RDG), pode ser encarado como uma generalização do algoritmo LMS, portanto faz uso da aprendizagem por correção de erro. A RDG (neste trabalho o GLMS será tratado por RDG), como no LMS, atualiza os pesos do neurônio segundo a retropropagação do erro (*error back-propagation*), ou simplesmente *Backpropagation* (HAYKIN, 2001). O trabalho de Rumelhart *et al.* (1986) apresentado ao *Massachusetts Institute of Technology* (MIT) promoveu a popularização do algoritmo *Backpropagation* para o aprendizado de redes neurais.

A diferenciação entre a correção do erro proposto pelo algoritmo LMS frente ao que ocorre com a RDG, se dá especialmente pelo cálculo do gradiente local. De acordo com Haykin (2001), no LMS observa-se apenas uma estimativa para o gradiente local, diferentemente do que ocorre com a RDG, que utiliza a derivada da função de ativação aplicada à saída do

combinador linear para o cálculo do gradiente local, e assim têm-se o valor efetivo do gradiente e não uma estimativa. A Equação (20) apresenta a forma geral para encontrar o gradiente local segundo a RDG.

$$\delta_k(n) = e_k(n)\varphi'_k(v_k(n)) \quad (20)$$

Na Seção 2.3 foi apresentado o algoritmo RMSProp com o objetivo de adicionar a característica de atualização dinâmica à  $\eta$  no tempo  $n$ . Dessa forma a atualização dos pesos por meio da regra delta generalizada com taxa de aprendizado dinâmica considerando o algoritmo RMSProp demonstrado na Equação (21), altera ligeiramente o que se observa a propósito da Equação (19), onde a taxa de aprendizado não sofre alteração ao longo do tempo.

$$w_{kj}(n+1) = w_{kj}(n) + \Delta w_{kj}(n) \therefore \Delta w_{kj}(n) = \eta(n)\delta_k(n) \quad (21)$$

## 2.5 ALGORITMO

O algoritmo para o treinamento de uma rede neural do tipo supervisionado e baseado na correção de erro considera dois níveis de computação. Inicia-se o processamento propagando-se os estímulos pela rede, método identificado como *forward* (computação para frente). Em seguida executa-se a computação no sentido contrário, ou seja, tem-se a atualização dos pesos, método conhecido como *backward* (computação para trás). Os passos que executam a computação pelos métodos *forward* e *backward* realizam o treinamento da rede neural. O alvo do treinamento é minimizar o erro entre o objetivo desejado,  $d_k$ , e o calculado,  $y_k$ . De tal sorte que o erro entre  $d_k$  e  $y_k$  se aproxime de 0.

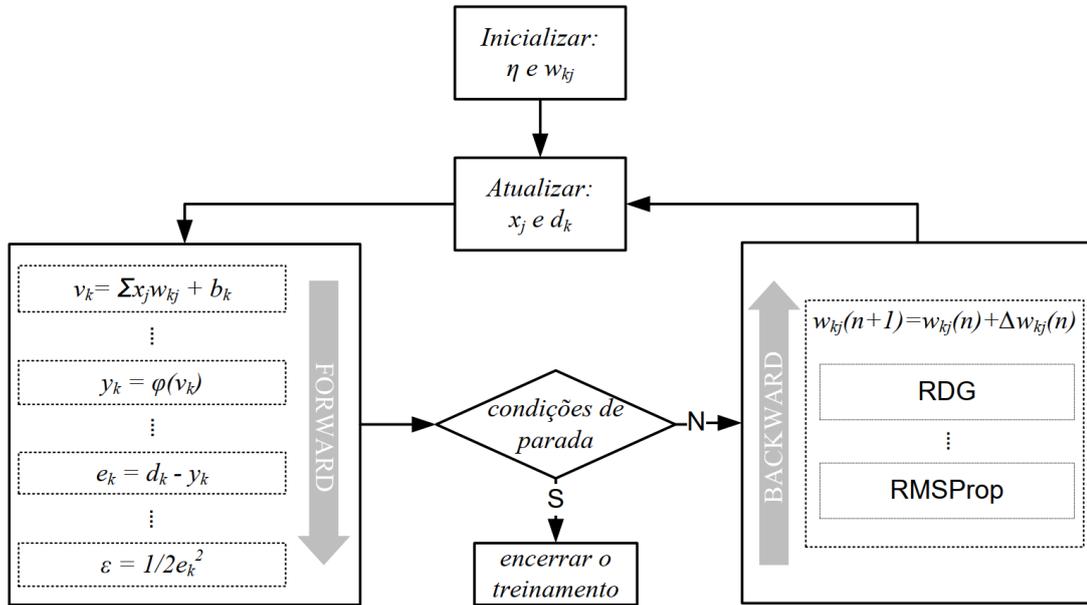
Desde que o algoritmo entra em ação os pesos estão sendo corrigidos e atualizados sob o prisma de um supervisor até que se alcance um número máximo de iterações ou um limiar de aprendizado, ambos definidos previamente. A saída é atualizada apenas na medida que  $\varepsilon$  torna-se menor que o valor de *threshold*, o qual representa uma tolerância para o aprendizado, e  $n$  a quantidade de iterações (HAYKIN, 2001). Após o treinamento da rede neural o algoritmo é encerrado e o processamento propriamente dito da RNA fica à caráter do bloco *forward*, onde os dados são amostrados nas entradas da rede e propagados a partir do nó de processamento.

Com o objetivo de ampliar a percepção geral do algoritmo proposto para o treinamento da RNA desenvolveu-se o diagrama da Figura 11.

## 2.6 ARQUITETURA MONOCAMADA

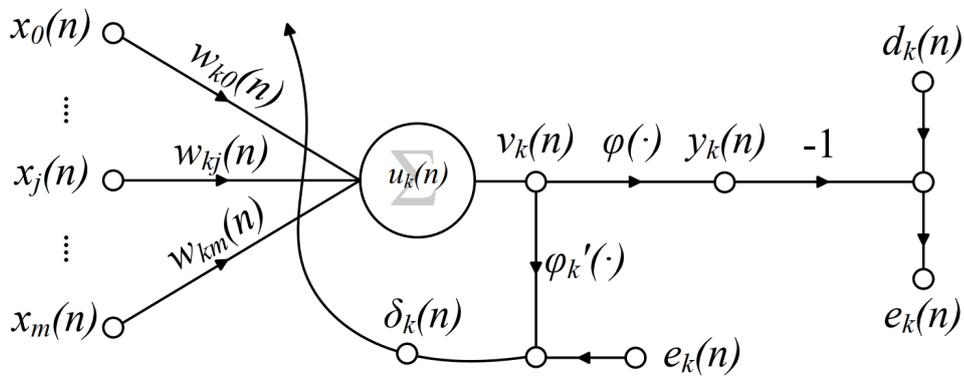
A Figura 12 define uma RNA monocamada com aprendizado supervisionado e correção de erro por meio da RDG. A RNA em questão representa uma generalização do Perceptron proposto por Rosenblatt (1958). A arquitetura neuronal da rede considera uma função de ativação com característica não-linear, promovendo uma limitação suave na ativação do neurônio, o que não se observa no Perceptron original.

Figura 11 – Algoritmo referente a RNA com aprendizado supervisionado por correção de erro.



Fonte: Autoria própria.

Figura 12 – RNA monocamada com apenas um nó de processamento.



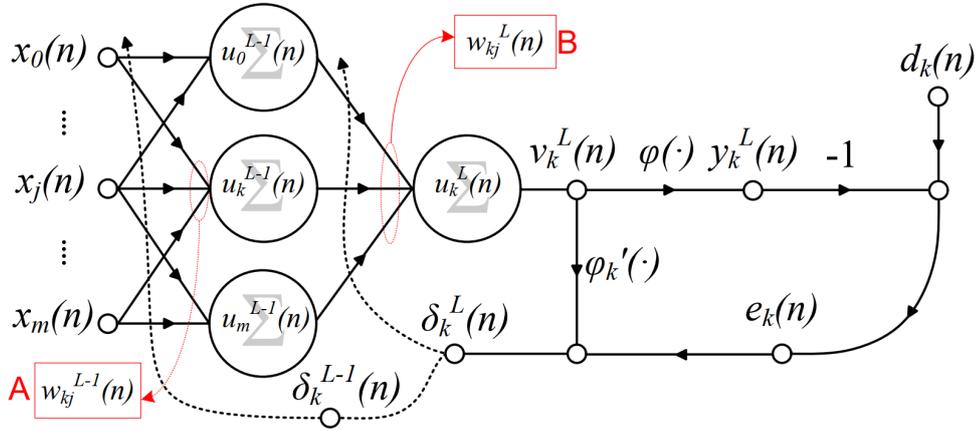
Fonte: Adaptado de (HAYKIN, 2001)

## 2.7 ARQUITETURA MULTICAMADA

De modo geral uma RNA multicamada trata de uma arquitetura que descreve uma rede neural que tenha pelo menos uma camada oculta. Na Figura 13 têm-se uma rede neural do tipo *Multilayer Perceptron* (MLP), a qual trata de uma extensão da arquitetura vista na Figura 12. Para a MLP em questão a camada oculta, de índice  $L - 1$ , é composta de 3 neurônios e a de saída, de índice  $L$ , possui apenas 1 neurônio. Nos pontos B e A, observa-se os pesos relativos ao neurônio da camada de saída  $w_{kj}^{(L)}$  e os pesos relativos aos neurônios da camada oculta  $w_{kj}^{(L-1)}$ . A definição para a MLP no contexto desse estudo segue o modelo apresentado

por Haykin (2001).

Figura 13 – RNA multicamada com  $m$  nós sensoriais na camada de entrada, 3 nós de processamento na camada oculta e apenas 1 nó de processamento na camada de saída.



Fonte: Adaptado de (HAYKIN, 2001)

Os pesos  $w_{kj}^{(L-1)}$  são propriedade dos neurônios  $k$  da camada  $L - 1$  que encontram-se conectados às entradas  $x_j$  da camada de entrada. Já os pesos  $w_{kj}^{(L)}$  pertencem ao neurônio  $k$  da camada  $L$  e têm como entrada as saídas  $y_k^{(L-1)}$ . De modo que  $\delta_k^{(L-1)}$  e  $\delta_k^{(L)}$ , nessa ordem, representam os gradientes locais dos neurônios da camada oculta e de saída, como consta na Figura 13. Os índices ligados aos nós computacionais variam de 0 até a  $m$ -ésima ordem. A identificação das camadas foram definidas a partir da camada  $L$ .

A atualização dos pesos de uma RNA multicamada com aprendizado por meio da correção do erro e sob supervisão, fica a cargo dos gradientes locais de cada camada a partir da camada de saída. Para se encontrar  $\delta_k^{(L)}$  considera-se  $e_k$ , como observado na Equação (20) e disposto na Figura (13), porém, para as camadas ocultas a partir  $\delta_k^{(L-1)}$  até a camada de entrada, não se aplica o erro no cálculo do gradiente local e sim o gradiente da camada adjacente, por exemplo, para se obter  $\delta_k^{(L-1)}$  utiliza-se  $\delta_k^{(L)}$  e não  $e_k$ .

De modo a generalizar a solução para o cálculo dos pesos, ter-se-á o índice da primeira camada oculta por  $\ell$  e os índices para os neurônios, no contexto das camadas, a partir da saída por  $k$ ,  $j$  e  $i$ . Dessa forma, considerando o exemplo da Figura 13,  $\ell$  aponta para  $L - 1$ . De modo que  $\ell \pm I$  aponta para as camadas adjacentes à primeira camada oculta tanto à direita quanto à esquerda e  $I$  determina o incremento dos índices destas camadas na rede. Portanto, a representação geral para a definição dos gradientes locais pode ser encontrada ao considerar a Equação (22).

$$\delta_j^{(\ell)}(n) = \varphi_j'(v_j^{(\ell)}(n)) \sum_k \delta_k^{(\ell+I)}(n) w_{kj}^{(\ell+I)}(n) \quad (22)$$

A Equação (23) apresenta a atualização dos pesos para as camadas ocultas, onde se tem a propagação do ajuste dos pesos ao longo do processamento previsto pelo método *backward*. Onde  $\eta(n)$  trata da taxa de aprendizado atualizada dinamicamente de acordo com o algoritmo RMSProp.

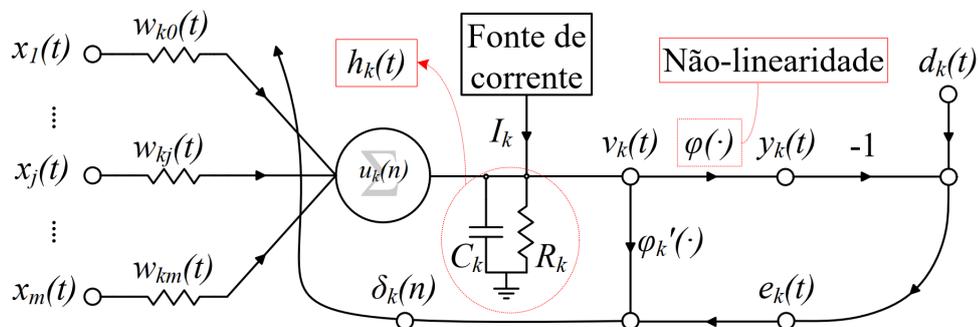
$$w_{kj}^{(\ell)}(n+1) = w_{kj}^{(\ell)}(n) + \eta(n)\delta_k^{(\ell)}(n)y_j^{(\ell-1)} \quad (23)$$

## 2.8 MODELO ADITIVO DE UM NEURÔNIO

O tempo representa uma entidade essencial no que tange o processo de aprendizagem. A partir da adição do tempo na atividade de uma rede neural é possível adicionar a capacidade de seguir as constantes alterações estatísticas compreendidas em processos como, por exemplo, os sinais da fala, ondas sonoras, flutuações no mercado imobiliário etc (HAYKIN, 2001).

A Figura 14 representa um filtro que modela a propriedade espaço-tempo de um neurônio. De maneira singular, o acréscimo de memória de curto prazo na estrutura de uma rede neural de característica estática, adiciona a sua saída particularidade temporal, o que corrobora para a transição da rede de estática para dinâmica, o que favorece a construção de sistemas dinâmicos não-lineares (HAYKIN, 2001).

Figura 14 – RNA com aprendizado supervisionado e atualização dos pesos por correção de erro modelada para um neurônio aditivo.



Fonte: Adaptado de (HAYKIN, 2001)

A transformação de uma rede de estática para dinâmica é direta. O circuito  $R_kC_k$  reflete o aspecto de memória de tempo contínuo, caracterizado por  $h_k(t)$ , que representa uma resposta a um impulso que decai de maneira exponencial no decorrer do tempo  $t$ .

Considerando o modelo neuronal aditivo, o circuito  $R_kC_k$  aplica ao neurônio a qualidade de memória analógica, e assim  $h_k(t)$  modela as particularidades temporais pós sinápticas. Outro ponto de destaque na arquitetura do neurônio aditivo é a distinção de responsabilidades, a rede é responsável pela figuração estática e a memória pelo tempo (HAYKIN, 2001).

Segundo Haykin (2001), uma escolha trivial e comum para  $h_k(t)$  trata de uma modelagem a partir da exponencial definida pela constante de tempo  $\tau_k$ , como consta na Equação (24).

$$h_k(t) = \frac{1}{\tau_k} \exp\left(-\frac{t}{\tau_k}\right) \quad \therefore \tau_k := R_k C_k \quad (24)$$

A formulação para  $v_k(t)$  para o modelo de neurônio aditivo segue ao que se observa na Equação (25), onde o asterisco denota a convolução entre o sinal de entrada  $x_j(t)$ , ponderado por  $w_{kj}(t)$ , e o impulso  $h_k(t)$ .

$$v_k(t) = h_k(t) * \left( \sum_{j=1}^m w_{kj} x_j(t) \right) + b_k \quad (25)$$

Como o destaque do modelo neuronal aditivo é em relação ao tempo, a RNA descrita na Figura 12 foi ligeiramente adaptada para representar esse aspecto, o que se evidencia na Figura 14. Sendo assim o processo de atualização dos pesos sinápticos para a rede em questão é o mesmo que se observa na Seção 2.4. A variável  $n$ , que denota o tempo discreto, foi alterada para  $t$ , que representa o tempo contínuo, e isso se fez necessário devido a característica analógica de  $h_k$ .

Os pesos sinápticos ganharam símbolos que denotam resistências, pois representam as condutâncias relativas as entrada, que por sua vez representam potenciais (i.e., tensões). O combinador linear é visto sob o prisma de um sistema com baixa impedância de entrada, ganho unitário de corrente e elevada impedância de saída.

A fonte de corrente observada na Figura 14 define uma característica peculiar do modelo de neurônio aditivo, a representação do bias  $b_k$  é disposta após a junção aditiva, na forma de uma corrente constante  $I_j$ , ressaltando a influência externa de  $b_k$ . Com isso pode-se readequar a Equação (25) para (26), onde se calcula a corrente total que alimenta o circuito  $R_k C_k$  a partir do termo  $w_{kj} x_j(t) + I_k$  (HAYKIN, 2001).

$$v_k(t) = h_k(t) * \left( \sum_{j=1}^m w_{kj} x_j(t) \right) + I_k \quad (26)$$

## 2.9 CONCLUSÃO

A revisão aplicada neste capítulo as redes neurais encontra-se voltada para o aprendizado supervisionado, contudo não encerra o assunto como definitivo, pelo contrário, trata apenas de uma fatia do extenso arcabouço que envolve os estudos das redes neurais. No entanto, considera-se que o material apresentado cobre todos os aspectos metodológicos necessários para o delineamento do ANNC.

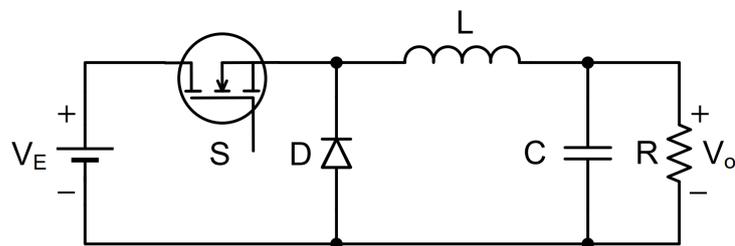
### 3 RETIFICADORES BUCK PFC

O objetivo deste capítulo é apresentar uma revisão dos principais aspectos da topologia que será utilizada para o retificador Buck PFC. Portanto, serão apresentadas as etapas de operação, as principais formas de onda, bem como a modelagem e o equacionamento. De modo que a Seção 3.1 apresenta o Buck como conversor CC-CC, o qual, segundo a análise, opera no limite do Modo de Condução Contínua (MCC) e na Seção 3.2 considera-se o Buck como conversor CA-CC, operando como PFC.

#### 3.1 CONVERSOR BUCK CC-CC

O conversor abaixador de tensão, Figura 15, também denominado conversor Buck, tem como objetivo produzir uma tensão de saída cujo o valor médio é inferior ao valor médio da tensão de entrada. Outro aspecto que se observa é a condição da corrente média de saída, que apresenta-se maior que a corrente média de entrada, tal comportamento se atribui ao princípio da conservação de energia (BARBI; MARTINS, 2000).

Figura 15 – Conversor Buck.



Fonte: Autoria própria.

Conceitualmente o conversor do tipo Buck, é desenvolvido de modo a proporcionar uma tensão média na saída, ou seja, na carga, que pode variar continuamente de zero até ao valor médio da tensão encontrada em sua entrada. O ajuste observado na tensão de saída se dá por meio, em sua maioria, do sinal PWM com frequência fixa. O fato da frequência fixa se deve a interferência eletromagnética, a qual pode ser reduzida fixando justamente a frequência do sinal PWM de controle (BARBI; MARTINS, 2000).

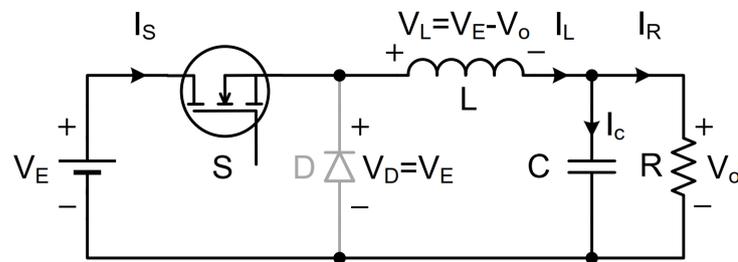
O diagrama de circuito que representa um conversor Buck pode ser observado a partir da Figura 15, para o qual não se considerou as suas não idealidades. Onde  $S$  é a chave eletrônica de potência e  $D$  trata-se do diodo de roda livre. A tensão contínua de entrada é identificada por  $V_E$  e a carga por  $R$ , de modo que a tensão de saída  $V_o$  é medida sobre  $R$ . Também se observa um filtro  $LC$  passa-baixa de segunda ordem sintonizado para eliminar a frequência de chaveamento, onde  $C$  representa a capacitância e  $L$  a indutância do filtro.

### 3.1.1 ETAPAS DE OPERAÇÃO

O desenvolvimento das etapas de operação consideram os trabalhos desenvolvidos por Hart (2016) e Rashid (2017) onde, de acordo com a ação da chave eletrônica  $S$  sobre o conversor, têm-se dois pontos de operação: (i) ocorre quando a chave está fechada e, (ii) quando a chave está aberta. As Figuras 16 e 17 demonstram justamente os dois estados de operação do conversor.

O estado em que a chave encontra-se fechada o diodo  $D$  apresenta-se polarizado inversamente e a corrente flui de  $V_E$  para o circuito  $RC$  visto na saída, onde o capacitor  $C$  é recarregado.

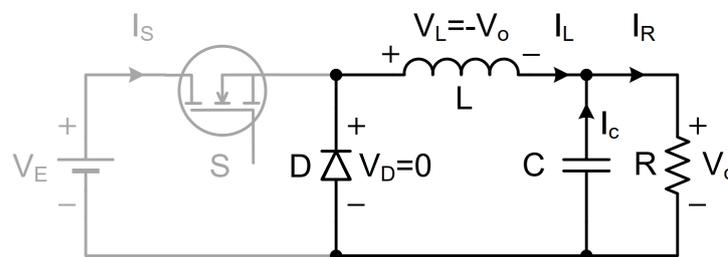
Figura 16 – Etapa de operação onde o conversor encontra-se com a chave fechada.



Fonte: Autoria própria.

Quando o conversor encontra-se com a chave  $S$  aberta, a corrente armazenada no indutor  $L$  circula pelo diodo de roda livre fluindo para o circuito  $RC$ . Nesse estado o diodo  $D$  encontra-se diretamente polarizado e a tensão no capacitor tende a diminuir. Sem o diodo  $D$  a chave  $S$  estaria sujeita a sobretensões originadas da transição entre aberta e fechada.

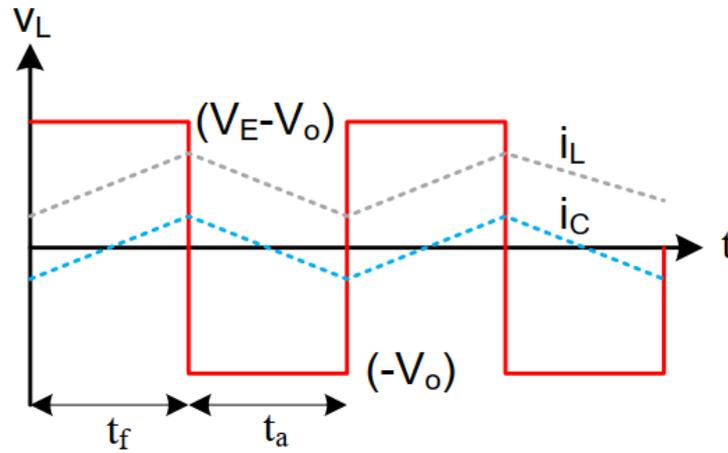
Figura 17 – Etapa de operação onde o conversor encontra-se com a chave aberta.



Fonte: Autoria própria.

Considerando que o conversor opere em regime permanente, onde  $t_f$  diz respeito ao período em que a chave permanece fechada e que  $t_a$  ao tempo que encontra-se aberta, segue que a tensão média sobre o indutor  $L$  é nula, o que pode ser evidenciado na Figura 18. Já na Figura 19 é possível conferir as principais componentes de tensão e corrente do conversor.

Figura 18 – Gráfico da tensão e da corrente sobre o indutor  $L$ . Também se observa o comportamento da corrente sobre  $C$  na medida que  $V_L$  varia.



Fonte: Autoria própria.

### 3.1.2 MODELAGEM

A modelagem do conversor fora determinada sob o prisma de Barbi (2015) e Martins (2000). As Equações (27) e (28) modelam o conversor quando a chave está fechada.

$$\frac{di_L}{dt} = \frac{1}{L}V_E - \frac{1}{L}V_o \quad (27)$$

$$\frac{dV_o}{dt} = \frac{1}{C}i_L - \frac{V_o}{RC} \quad (28)$$

As Equações (29) e (30) modelam o conversor quando a chave encontra-se aberta .

$$\frac{di_L}{dt} = -\frac{1}{L}V_o \quad (29)$$

$$\frac{dV_o}{dt} = \frac{1}{C}i_L - \frac{V_o}{RC} \quad (30)$$

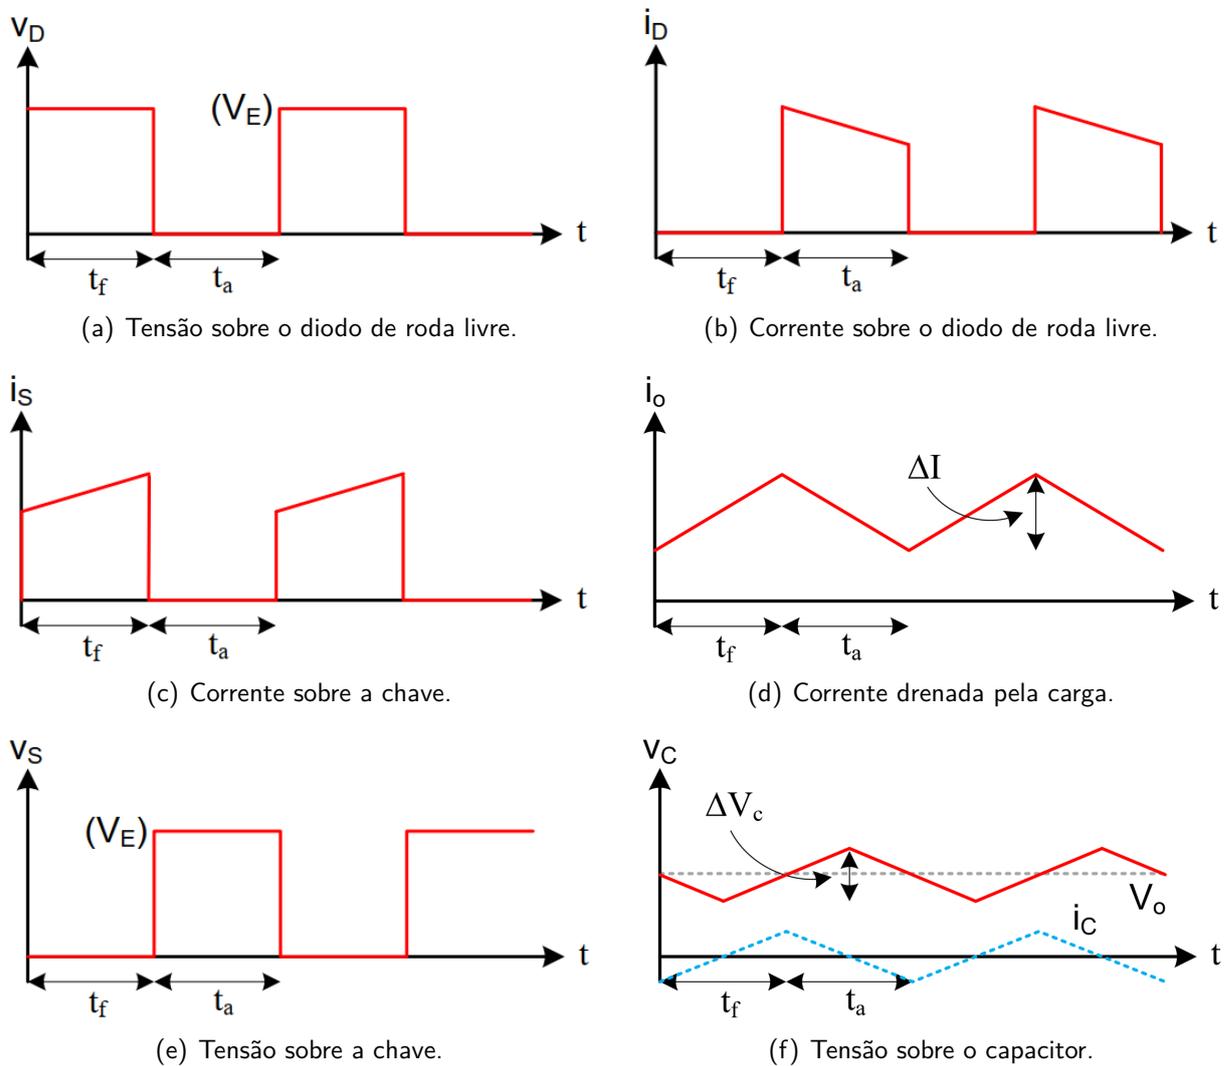
A análise por espaço de estados do conversor pode ser obtida a partir dos equacionamentos observados de (27) a (30). Dessa forma tem-se a representação do sistema para chave fechada na Equação (31) e para a chave aberta na Equação (32).

$$\frac{d}{dt} \begin{bmatrix} i_L \\ V_o \end{bmatrix} = \begin{bmatrix} 0 & -L^{-1} \\ C^{-1} & -(CR)^{-1} \end{bmatrix} \cdot \begin{bmatrix} i_L \\ V_o \end{bmatrix} + \begin{bmatrix} L^{-1} \\ 0 \end{bmatrix} \cdot V_E \quad (31)$$

$$\frac{d}{dt} \begin{bmatrix} i_L \\ V_o \end{bmatrix} = \begin{bmatrix} 0 & -L^{-1} \\ C^{-1} & -(CR)^{-1} \end{bmatrix} \cdot \begin{bmatrix} i_L \\ V_o \end{bmatrix} + \begin{bmatrix} 0 \\ 0 \end{bmatrix} \cdot V_E \quad (32)$$

Aplicando os tempos  $(1 - D)$  para a chave aberta e  $(D)$  para a chave fechada nas Equações (31) e (32) respectivamente, tem-se as Equações (33) e (34).

Figura 19 – Principais formas de onda para o conversor operando no limite da condução contínua.



Fonte: Autoria própria.

$$\frac{d}{dt} \begin{bmatrix} i_L \\ V_o \end{bmatrix} = \begin{bmatrix} 0 & -L^{-1} \\ C^{-1} & -(CR)^{-1} \end{bmatrix} \cdot \begin{bmatrix} i_L \\ V_o \end{bmatrix} + \begin{bmatrix} L^{-1} \\ 0 \end{bmatrix} \cdot D \cdot V_E \quad (33)$$

$$\frac{d}{dt} \begin{bmatrix} i_L \\ V_o \end{bmatrix} = \begin{bmatrix} 0 & -L^{-1} \\ C^{-1} & -(CR)^{-1} \end{bmatrix} \cdot \begin{bmatrix} i_L \\ V_o \end{bmatrix} + \begin{bmatrix} 0 \\ 0 \end{bmatrix} \cdot (1 - D) \cdot V_E \quad (34)$$

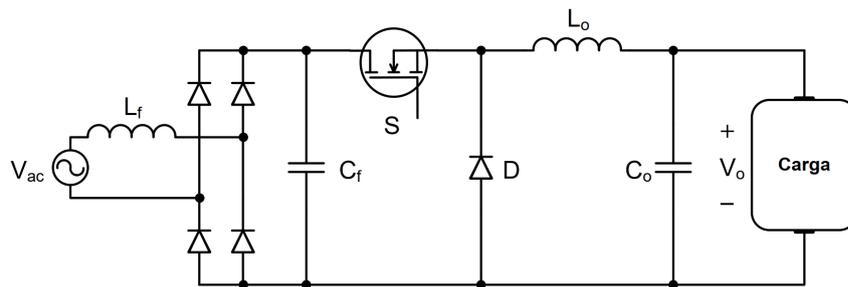
Somando-se as Equações (33) e (34) tem-se o equacionamento geral para o conversor Buck, que descreve tanto o estado da chave aberta quanto fechada, o qual pode ser conferido na Equação (35).

$$\frac{d}{dt} \begin{bmatrix} i_L \\ V_o \end{bmatrix} = \begin{bmatrix} 0 & -L^{-1} \\ C^{-1} & -(CR)^{-1} \end{bmatrix} \cdot \begin{bmatrix} i_L \\ V_o \end{bmatrix} + \begin{bmatrix} L^{-1} \\ 0 \end{bmatrix} \cdot D \cdot V_E \quad (35)$$

### 3.2 RETIFICADOR BUCK PFC MONOFÁSICO

Considerando as várias topologias de conversores encontradas na literatura empregadas para a correção do fator de potência em retificadores destaca-se a arquitetura Buck, ilustrada na Figura 20, a qual foi escolhida nos estudos referente a este trabalho devido a potencial aplicação. A correção do fator de potência fica à cargo da estratégia de controle, que tem como objetivo fazer com que corrente e tensão de entrada permaneçam em fase.

Figura 20 – Retificador Buck PFC monofásico.



Fonte: Autoria própria.

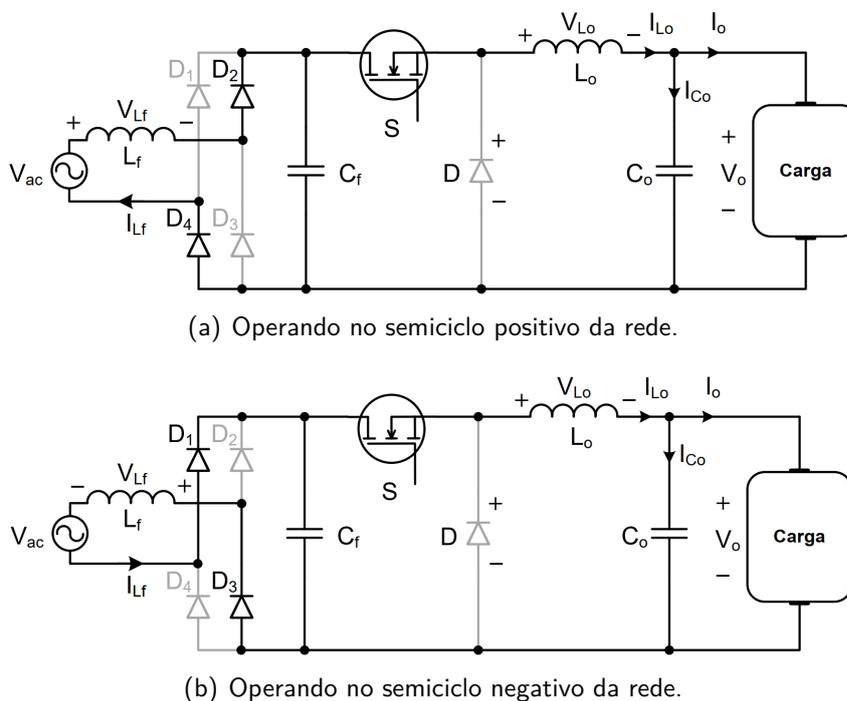
Os estágios de operação do conversor Buck PFC, possuem etapas de funcionamento similares do conversor CC-CC Buck descrito na Seção 3.1. As Figuras 21(a) e 21(b) destacam a operação do retificador no decorrer da comutação da chave, tanto para o semiciclo positivo quanto para o semiciclo negativo da rede. Já a Figura 22 descreve a operação do retificador para o instante em que a chave encontra-se aberta, portanto, o destaque é para o circuito de saída.

#### 3.2.1 OPERANDO COMO PFC

O conversor Buck, de modo geral, tem uso restrito como PFC, porque introduz uma região de corrente nula na entrada. A descontinuidade no modo de operação do Buck é devido ao indutor de saída que faz com que a corrente de entrada seja nula enquanto o valor instantâneo da tensão de entrada permaneça menor que a tensão média de saída. Sendo assim a DHT da corrente de entrada fica sujeita ao valor médio da tensão de saída e o valor de pico da tensão de entrada (SOUZA, F. P.; BARBI, 1999). De acordo com Pomilio (2007), o ângulo que aponta para o intervalo da ausência de corrente na entrada pode ser calculado pela Equação (36), e quanto maior o intervalo maior será a DHT, o que de igual modo altera negativamente o FP.

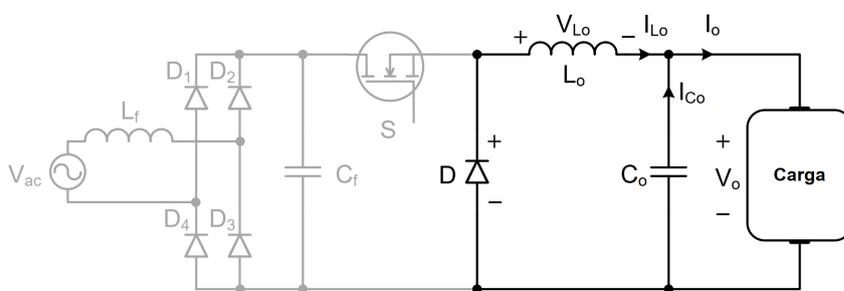
$$\varphi = \sin^{-1} \left( \frac{V_o}{V_{ac(pico)}} \right) \quad (36)$$

Figura 21 – Estágios de operação do retificador Buck PFC para a chave fechada.



Fonte: Autoria própria.

Figura 22 – Estágio de operação do retificador Buck PFC para a chave aberta.

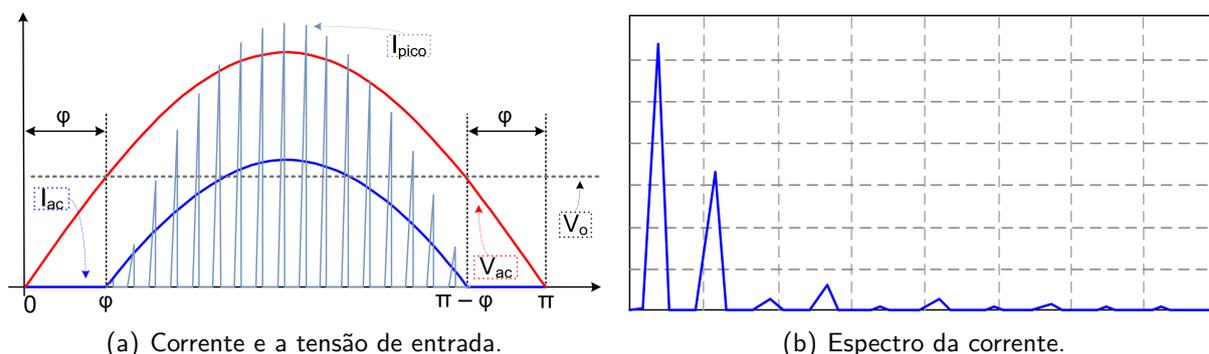


Fonte: Autoria própria.

Outra desvantagem do modo de operação descontínuo é tratar das altas correntes de pico e eficaz na entrada, o que corrobora para esforço extra dos dispositivos de comando e, conseqüentemente, perdas na condução das chaves. As altas correntes de entrada, além de provocar perdas de condução nas chaves de comando, também influenciam a geração de harmônicos de corrente, em especial as de 3ª e 5ª ordem. A Figura 23 ilustra os principais aspectos de um retificador Buck PFC com modulação senoidal e frequência fixa em modo descontínuo de condução.

Além do projeto de um retificador Buck PFC considerar o proposto por Barbi (2006) e Pomilio (2007) no que diz respeito a frequência fixa e a modulação senoidal na composição do sinal PWM de controle, o indutor de saída apresenta-se como uma restrição de projeto. Onde,

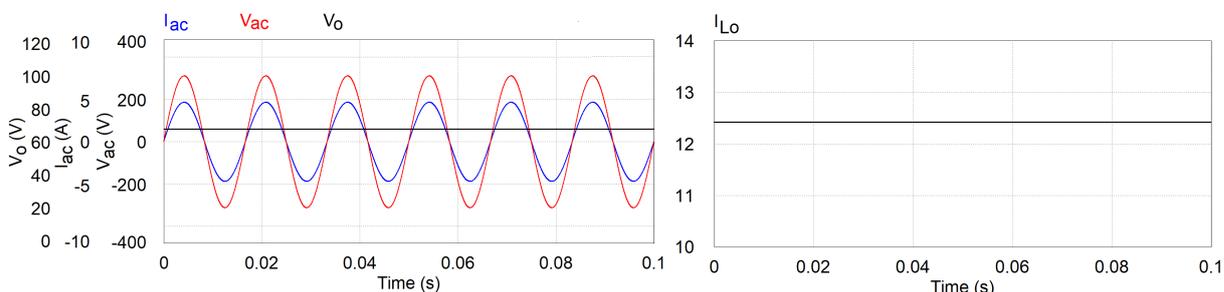
Figura 23 – Retificador Buck com PFC em Modo de Condução Descontínua.



Fonte: Adaptado de (POMILIO, 2007).

para que este opere em modo de condução contínua, se comportando como fonte de corrente, e assim atendendo ao requisito de um PFC unitário, ou próximo disso, o tamanho e peso desse indutor implica, de modo geral, em uma estrutura volumosa, dificultando a implantação do protótipo (SOUZA, F. P.; BARBI, 1999). Na Figura 24 são apresentadas as principais formas de onda para um retificador Buck idealizado para um PFC igual a 1.

Figura 24 – Formas de onda para um retificador Buck idealizado.



(a) Formas de onda para a corrente e a tensão de entrada, (b) Forma de onda para a corrente sobre o indutor bem como para a tensão média de saída.

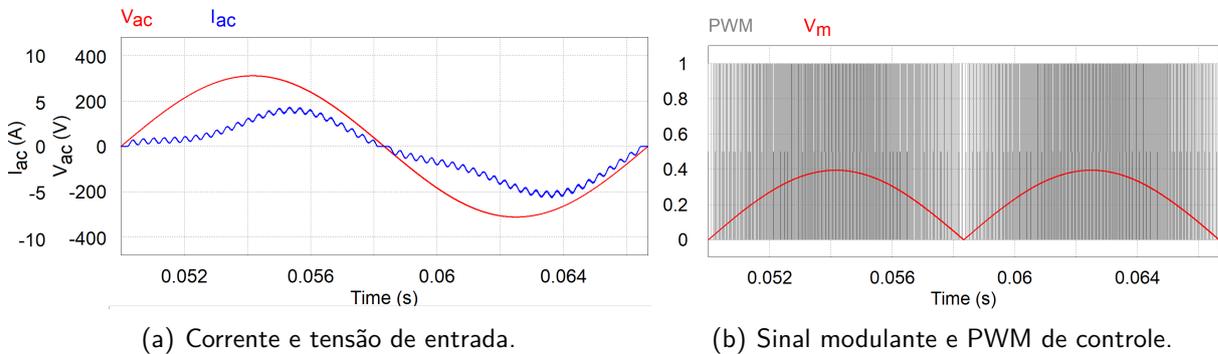
Fonte: Autoria própria - Simulador PSIM.

A Figura 25 ilustra o Buck PFC operando sem estratégia para correção do fator de potência, e a Figura 26 apresenta os resultados para a aplicação da técnica *Feedforward Current*, a partir da qual permite ao retificador operar no modo de condução contínua (MCC), sendo possível reduzir os esforços nas chaves de comando e também minimizar a dimensão do indutor de saída.

### 3.2.2 CONTROLE FEEDFORWARD PARA O BUCK PFC

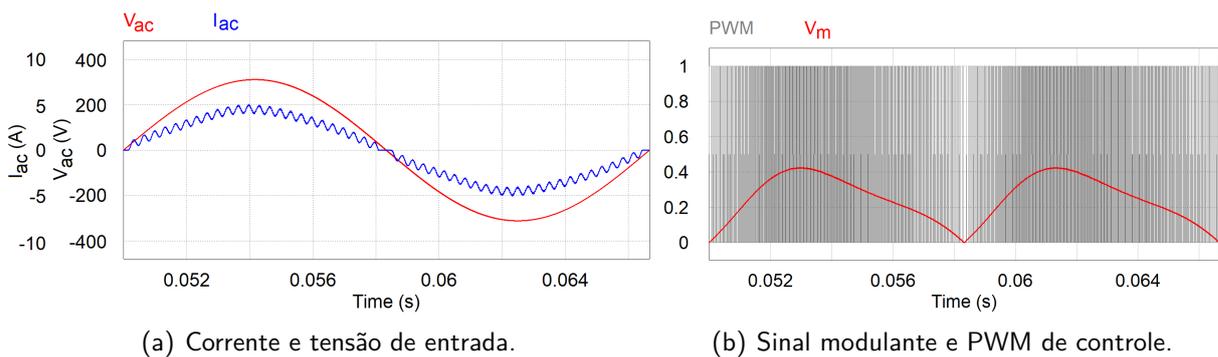
Na Figura 27 é apresentado o diagrama da estratégia de controle para o Buck PFC baseada na malha fechada da corrente do indutor de saída, que tem como objetivo corrigir o atraso da corrente frente a tensão de entrada, como apresentado por F Pottker Souza e Barbi (1999). A estratégia considera minimizar as sobrecorrentes de entrada, como observado

Figura 25 – Formas de onda para um retificador Buck PFC modulado via PWM com frequência fixa sem controle para o PFC, com indutor de saída de  $15\text{ mH}$ . Os demais parâmetros podem ser observados na Tabela 3.



Fonte: Autoria própria - Simulador PSIM.

Figura 26 – Formas de onda para um retificador Buck PFC modulado via PWM com frequência fixa e estratégia *feedforward Current* para correção do PFC, com indutor de saída da  $15\text{ mH}$ . Os demais parâmetros podem ser observados na Tabela 3.



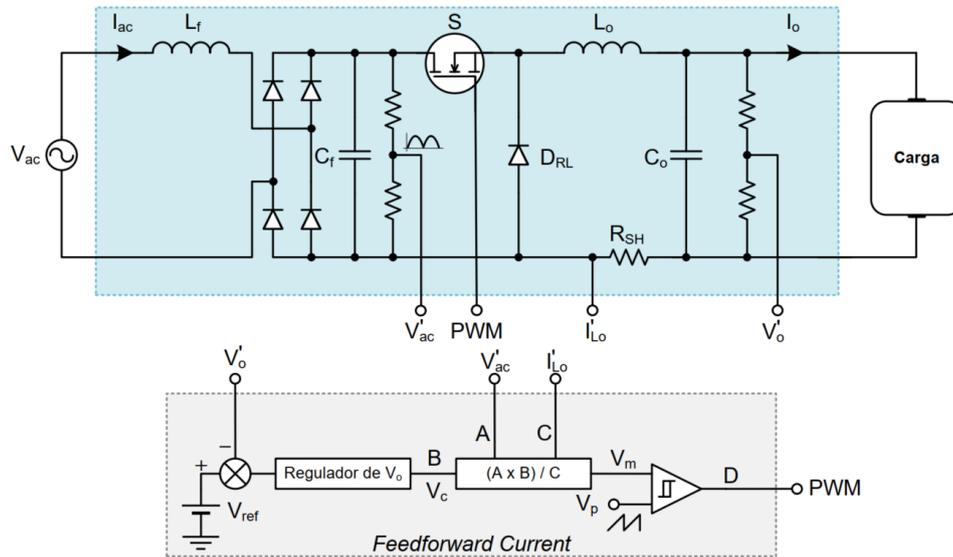
Fonte: Autoria própria - Simulador PSIM.

na Figura 23(a) para  $I_{pico}$ , e também reduzir a dimensão do indutor de saída. A partir da ondulação da corrente do indutor de saída a estratégia *Feedforward Current*, ajusta o sinal modulante de maneira que a diferença de fase na corrente em relação a tensão de entrada é corrigida.

No tocante a identificação dos termos da Figura 27 tem-se que:  $V_{ac}$  e  $I_{ac}$  representam a tensão e corrente de entrada respectivamente,  $L_f$  e  $C_f$  representam o indutor e o capacitor do filtro de entrada, bem como  $L_o$  e  $C_o$  representam o indutor e capacitor do filtro de saída.  $S$  e  $D_{RL}$  representam a chave de comutação e o diodo de roda livre, e  $R_{SH}$  (*shunt*) o resistor de amostragem da corrente de saída.  $V_c$  representa o sinal de saída do controlador de tensão,  $V'_{ac}$  a amostra da tensão de entrada e  $I'_{L_o}$  a amostra da corrente sobre o indutor de saída.

No controle promovido pelo método *Feedforward Current* as Equações (37) e (38) determinam os sinais modulador e portador, onde o portador trata de uma dente-de-serra.

Figura 27 – Diagrama da estratégia de controle para o Buck PFC baseada na malha fechada da corrente do indutor de saída.



Fonte: Adaptado de (SOUZA, F. P.; BARBI, 1999)

$$V_m(t) = \frac{A \cdot B}{C} = \frac{V_c V_{ac(pico)} \text{sen}(wt)}{R_{SH} \left( I_o - \frac{\Delta I_o}{2} \text{sen}(2wt) \right)} \quad (37)$$

$$V_p(t) = V_{p(pico)} \quad (38)$$

A razão cíclica,  $D$ , pode ser averiguada pela razão entre o sinal da moduladora e da portadora como evidenciado pela Equação (39).

$$D(t) = \frac{V_m(t)}{V_p(t)} = \frac{V_c V_{ac(pico)} \text{sen}(wt)}{V_{p(pico)} R_{SH} \left( I_o - \frac{\Delta I_o}{2} \text{sen}(2wt) \right)} \leq 1 \quad (39)$$

### 3.3 CONCLUSÃO

A técnica para o controle do FP apresentada por F Pottker Souza e Barbi (1999), tem como característica principal a baixa complexidade, fator de extrema relevância para este estudo, o que promove a abstração do método para uma RNA de tempo real em um microcontrolador, como observado no decorrer do capítulo.

## 4 RNA APLICADA AO RETIFICADOR BUCK

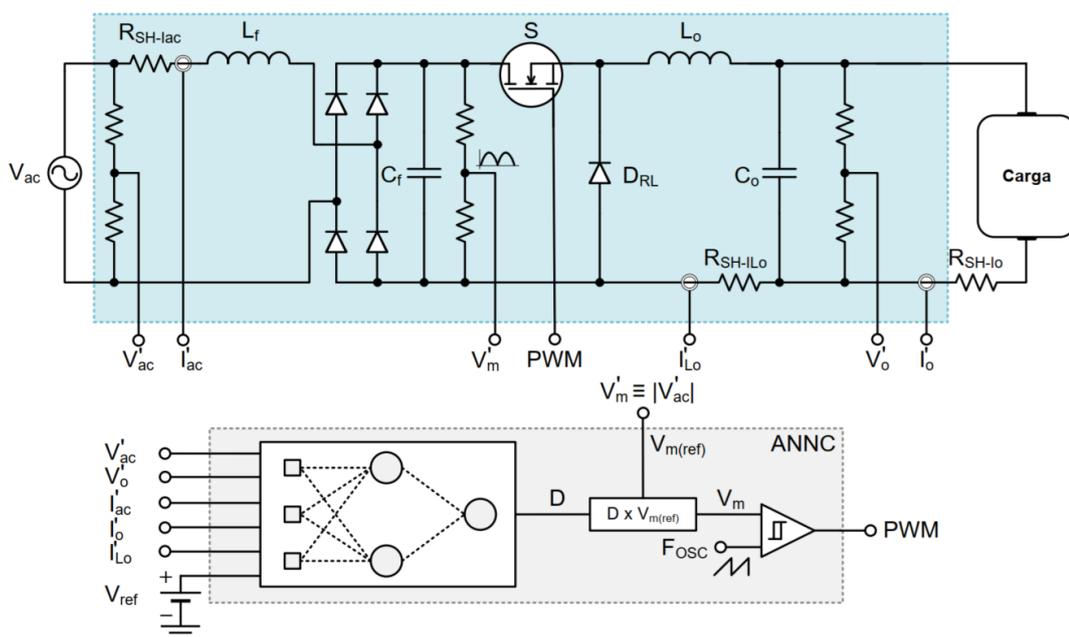
A metodologia utilizada para desenvolver o ANNC será apresentada neste capítulo, onde serão avaliadas a técnica do neurônio aditivo e a técnica *Feedforward Current* na atualização dos parâmetros internos do controlador. Também será apresentada a arquitetura neural para o ANNC e suas características específicas, bem como a análise de desempenho do modelo proposto. No entanto, a formalização da comprovação do método encontra-se na Seção 4.5, já os componentes principais do algoritmo escrito na linguagem C para o ANNC Monocamada encontram-se no Apêndice C.

### 4.1 ESTRATÉGIA DE CONTROLE

A estratégia proposta por este estudo visa aplicar uma rede neural com característica de tempo real ao controle do retificador Buck, onde a técnica de controle faz uso de um neurônio aditivo associado a técnica *Feedforward Current* desenvolvida por F Pottker Souza e Barbi (1999).

A consideração do neurônio aditivo ao modelo diz respeito a corrente de retorno do indutor de saída, onde esta, ao ser aplicada ao filtro *RC* de saída, promove a condição temporal necessária para o ajuste dos parâmetros internos da RNA e, como consequência, enquadra os sinais da corrente e da tensão de entrada. A Figura 28 ilustra o diagrama do sistema de controle proposto para o Buck PFC.

Figura 28 – Diagrama de blocos da estrutura de potência e de controle baseada em rede neural para o retificador Buck PFC.



Fonte: Autoria própria.

A configuração dos parâmetros de entrada do ANNC está de acordo com o observado na pesquisa apresentada por Mohagheghi *et al.* (2009), exceto por uma entrada adicional, a qual considera a corrente sobre a carga,  $I_{L_o}$ . Como ocorre na Seção 3.2.2, a seguir apresenta-se a descrição de cada um dos parâmetros que compõem a estrutura observada na Figura 28:

1.  $R_o$  representa a carga oferecida ao conversor.
2.  $V'_{ac}$  e  $I'_{ac}$  representam as amostras da tensão e da corrente de entrada,  $V'_o$  e  $I'_o$  determinam as amostras da tensão e da corrente média sobre  $R_o$ , e  $I'_{L_o}$  identifica amostra da corrente sobre o filtro indutivo de saída,  $L_o$ .
3.  $V_{ref}$  representa um valor de referência para a tensão de saída, o qual é tratado numericamente pelo ANNC.
4.  $V'_m \equiv |V'_{ac}| \equiv V_{m(ref)}$  representa a amostra da referência da tensão de entrada,  $V_{ac}$ , retificada.
5. As grandezas no contexto do ANNC encontram-se normalizadas no intervalo [0 1].

## 4.2 MODELAGEM DO ANNC

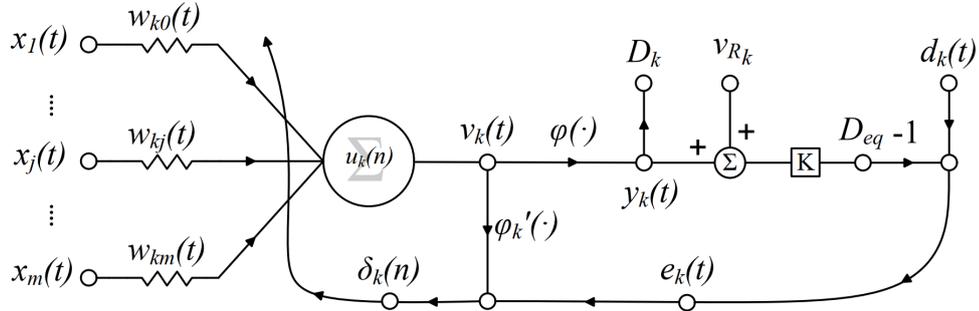
Na Figura 29 é apresentada a arquitetura base para as redes neurais aplicadas ao ANNC, onde é ilustrada a característica do neurônio aditivo. Ao considerar a Figura 29(b) é possível perceber a relação entre o circuito  $R_k C_k$  do neurônio aditivo, com o observado na saída do retificador Buck PFC para  $R_o C_o$ , onde  $R_o$  representa a carga conectada ao retificador,  $I_{L_o}$  a corrente sobre  $L_o$  e  $C_o$  o filtro capacitivo de saída. Portanto, os componentes  $L_o$ ,  $C_o$  e  $R_o$  do retificador Buck retratam o aspecto temporal dado por  $I_k$ ,  $C_k$  e  $R_k$  do neurônio aditivo.

O aspecto temporal introduzido ao ANNC ocorre por meio da tensão  $v_{R_k}$ , diferente do que se observa para o neurônio aditivo tradicional, onde para este o atributo temporal é adicionado de acordo com a convolução entre  $h_k$  e combinador linear  $v_k$ , o que implica em um preço computacional para o ANNC alto haja visto que, a priori, este constitui uma solução de tempo real.

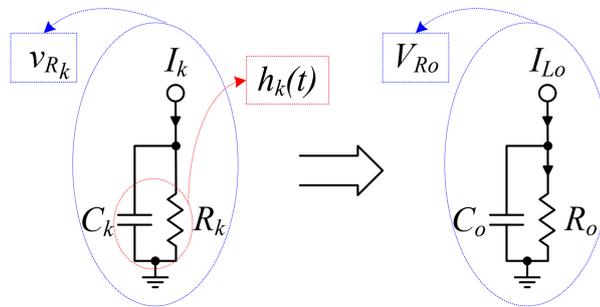
No contexto do retificador Buck,  $v_{R_k}$  é representada por  $V_{R_o}$ , a qual não trata de  $V_o$ , e sim da tensão de ondulação vista sobre  $R_o$  devido a  $I_{L_o}$ . A consequência ao adotar  $V_{R_o}$  como parâmetro do ANNC, em virtude de que esta encontra-se em função de  $I_{L_o}$ , além do aspecto temporal do neurônio aditivo, é a introdução da técnica *Feedforward Current* ao sistema de controle. Dessa forma o ANNC recebe os atributos temporais do neurônio aditivo que lhe permite recuperar de transitórios em  $I_{L_o}$ , bem como ajustar a forma do sinal da corrente  $I_{ac}$  por meio da técnica *Feedforward Current*.

Como o sistema de controle é não-linear, a delimitação geral para a função que rege o sistema pode ser observada na Equação (40). Onde  $x(t) \in \mathbb{R}^n$  trata do vetor das variáveis que

Figura 29 – Princípio do neurônio aditivo aplicado à camada de saída do sistema neural de controle sugerido para o ANNC. As variáveis  $x_1, \dots, x_m$ , para uma RNA multicamada, representam a saída da camada oculta anterior a camada de saída, e para uma RNA monocamada, representam os estímulos de entrada da rede neural.



(a) Rede neural com característica de neurônio aditivo.



(b) Propriedade temporal.

Fonte: Autoria própria.

se deseja controlar, no caso do ANNC trata-se apenas da variável  $D$ , que representa o ciclo ativo. Para  $u(t) \in \mathbb{R}^m$ , que representa o vetor das variáveis de controle do sistema, tem-se o vetor de entrada formado  $x_1, \dots, x_m, d_k$  e  $V_{R_k}$ , ou seja, as entradas do sistema. Como dito na Seção 1.2, o ANNC representa um sistema de controle "caixa preta", portanto tem como papel encontrar uma função  $u : [0, T] \rightarrow \mathbb{R}^m$  de modo que  $V_o$  e  $I_o$  tenham suas magnitudes controladas e que a fase de  $I_{ac}$  ajuste-se a de  $V_{ac}$ .

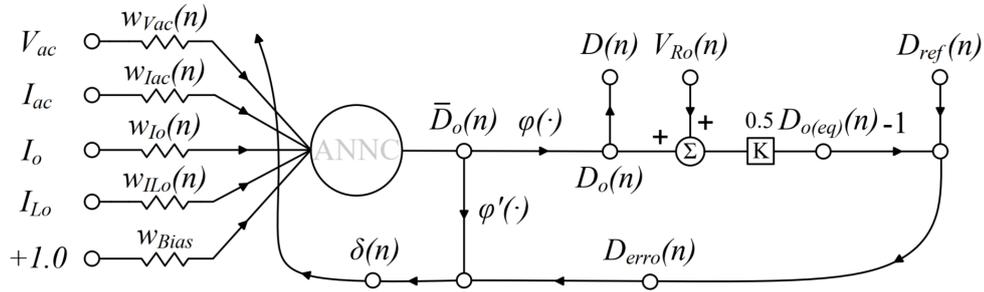
$$\dot{x}(t) = F(t, x(t), u(t)) \tag{40}$$

### 4.3 PARÂMETROS FORMAIS ASSOCIADOS AO ANNC

O ANNC baseado na arquitetura de uma rede neural monocamada pode ser acompanhado na Figura 30, de modo que os parâmetros observados na Figura 29 encontram-se atualizados para os valores formais na configuração do ANNC. Uma vez que a proposta da arquitetura do ANNC para o neurônio aditivo considera apenas o nó de saída, a representação do modelo se estende desde uma RNA Monocamada até às arquiteturas MLP.

A seguir apresenta-se a descrição dos parâmetros formais das redes neurais associadas ao ANNC:

Figura 30 – Configuração do ANNC para a RNA Monocamada.



Fonte: Autoria própria.

1.  $D_{ref}$  representa a razão cíclica desejada e refere-se numericamente a  $V_{ref}$ .
2.  $\bar{D}_o(n)$  denota a razão cíclica obtida na saída do combinador linear da rede neural, antes da ativação, a qual representa  $v_k$ .
3.  $D_o$  é a razão cíclica obtida após a ativação do neurônio, e é sinônimo de  $y_k$ .
4.  $D \equiv D_o$ , representa a razão cíclica base para  $V_m$ .  $D$  expressa a variável de controle do sistema a qual determina a magnitude de  $V_o$ , bem como o ajuste de fase devida à  $I_{ac}$ .
5.  $D_{erro}$  representa o erro calculado a partir de  $D_{ref}$  e  $D_{o(eq)}$ , e que reflete  $e_k$ , o qual pode ser determinado pela Equação (41).

$$D_{erro} = D_{ref} - D_{o(eq)} \quad (41)$$

6. O gradiente local pode ser calculado, nos termos dos parâmetros formais do ANNC, pela Equação (42).

$$\delta(n) = D_{erro}(n) \varphi'(\bar{D}_o(n)) \quad (42)$$

7. No tocante as redes neurais com apenas uma camada  $\varepsilon$  se resume na energia instantânea do erro, e encontra-se definido na Equação (43).

$$\varepsilon(n) = \frac{1}{2} (D_{erro})^2(n) \quad (43)$$

Uma vez que  $V_{R_o}$  trata de um parâmetro externo à rede neural associada ao ANNC e que encontra-se em função da corrente  $I_{L_o}$ , pode ser determinada pelo método a seguir:

1. O primeiro ponto a ser considerado é fato de  $R_o$  ser determinada a cada iteração do sistema, onde é calculada pela Equação (44). Ao computar  $R_o$  a cada iteração ( $n$ ) do algoritmo, considera-se além da tensão e da corrente média, os efeitos dos seus devidos valores de ondulação,  $\Delta V_o$  e  $\Delta I_o$ .

$$R_o(n) = V_o(n) / I_o(n) \quad (44)$$

2. A definição para a corrente sobre o indutor de saída,  $I_{L_o}$ , para um ângulo  $\theta$  na iteração ( $n$ ), de acordo como F Pottker Souza e Barbi (1999), é dada pela Equação (45).

$$I_{L_o}(\theta)(n) = I_o(n) - \frac{\Delta I_o}{2} \text{sen}(2\theta)(n) \quad (45)$$

3. De posse de  $R_o$  e de  $I_{L_o}$  pode-se encontrar  $V_{R_o}$ , que registra o valor da tensão de ondulação refletida na carga devido a corrente  $I_{L_o}$  na iteração ( $n$ ), de acordo com a Equação (46).

$$V_{R_o}(n) = R_o(n) \cdot I_{L_o}(n) \quad (46)$$

#### 4.4 RESPOSTA DO MÉTODO

O objetivo do método de controle proposto a partir do ANNC trata da atualização da razão cíclica modulante de modo que, tanto a tensão e corrente sobre a carga mantenham-se estáveis quanto o fator de potência se aproxime da unidade.

A correção dos parâmetros,  $I_o$ ,  $V_o$  e FP, ficam a cargo de  $D$ , que representa  $V_{R_o}$  deslocada de  $180^\circ$ . Contudo, para que o controle opere adequadamente, considerando que  $I_{L_o}$  encontra-se ligeiramente atrasada em relação  $V_m$ , tal que  $V_m \equiv |V_{ac}|$ , incorre que o ANNC fica sem referência para corrigir seus parâmetros internos por ângulo menor que  $\varphi$ , como apontado por Pomilio (2007).

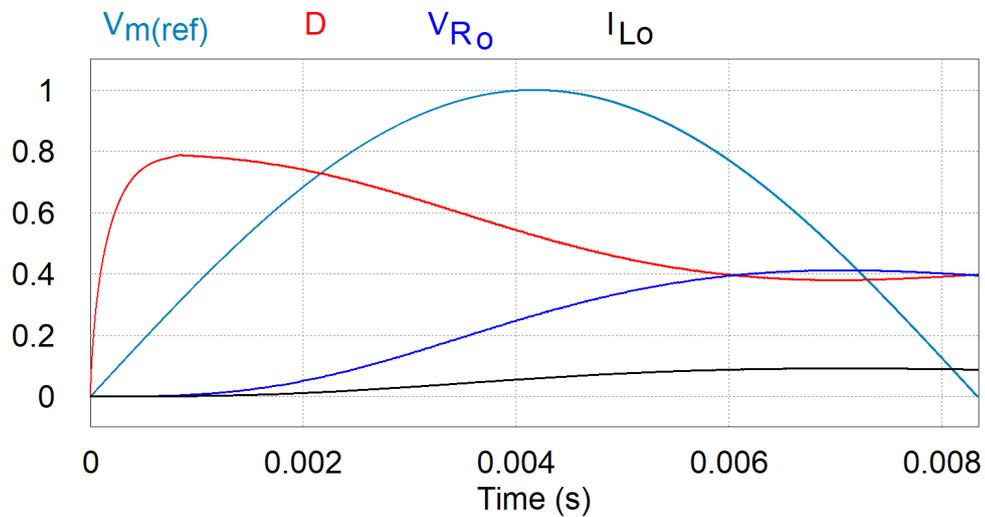
Na Figura 31 é possível identificar o intervalo no qual o ANNC encontra-se sem referência de  $V_{R_o}$  devido a  $I_{L_o}$ . Diante disso houve a necessidade de aplicar um fator de correção em  $V_m$  considerando apenas o primeiro semi-ciclo de  $V_{ac}$ , e assim limitar a correção da sua amplitude por um coeficiente de 0,4, o qual foi determinado de modo empírico.

A Figura 32 ilustra a razão cíclica modulante sem a devida correção para o primeiro ciclo de  $V_{m(ref)}$  (que representa o primeiro semi-ciclo de  $V_{ac}$ ). Já a Figura 33 detalha a aplicação do fator de correção para o primeiro ciclo de  $V_{m(ref)}$ . Ao comparar ambas as figuras percebe-se que, devido a aplicação das técnicas *Feedforward Current* e neurônio aditivo, o ANNC consegue corrigir adequadamente  $V_m$  após o ângulo  $\varphi$  do primeiro semi-ciclo de  $V_{ac}$  e se estende ao período de amostragem subsequente.

Ao considerar as características da razão cíclica  $D$ , percebe-se que o seu *offset* acompanha  $D_{o(eq)}$  como demonstrado no Apêndice A e ilustrado na Figura 33. Também se observa que o valor médio de  $V_o$  também se aproxima de  $D_{o(eq)}$ , haja visto, como esperado, que  $D_{o(eq)}$  se aproxima de  $D_{ref}$  na medida que o ANNC computa.

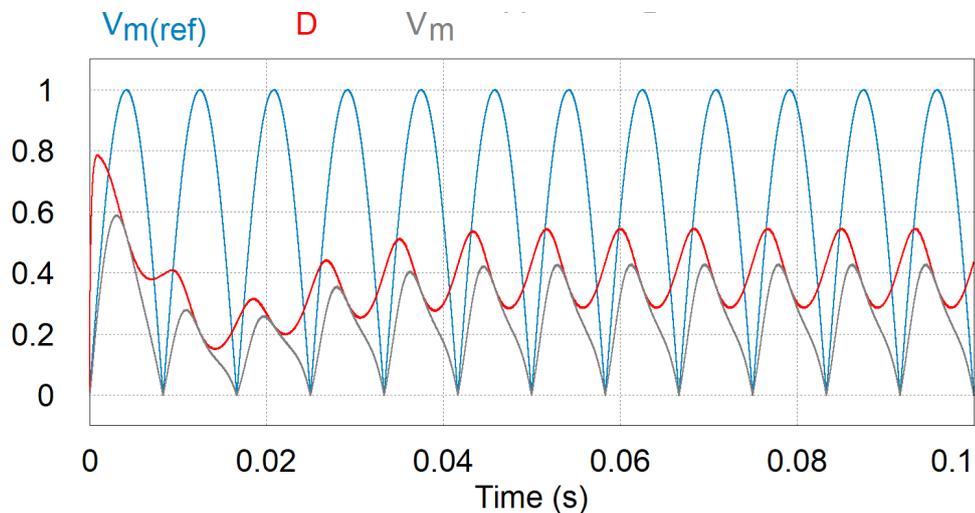
Também na Figura 33 encontra-se em destaque o comportamento de  $D_{o(eq)}$ , onde este assume o valor de  $D_{ref}$  rapidamente. Contudo, em virtude do amortecimento inserido no sistema pelo filtro *LC* de saída,  $V_o$  não é atualizada na mesma proporção. A atualização praticamente instantânea de  $D_{o(eq)}$  representa uma característica positiva para o ANNC, pois conduz o retificador a recuperar-se rapidamente de transitórios.

Figura 31 – Atraso entre  $V_m$  e  $I_{L_o}$  para o primeiro semi-ciclo de  $V_{ac}$ .  $V_{R_o}$  e  $I_{L_o}$  encontram-se normalizados no intervalo [0 1].



Fonte: Autoria própria - Simulador PSIM.

Figura 32 – Alteração na razão cíclica modulante no primeiro semi-ciclo de  $V_{ac}$  devido a falta de referência para o ANNC a partir  $V_{R_o}$ .

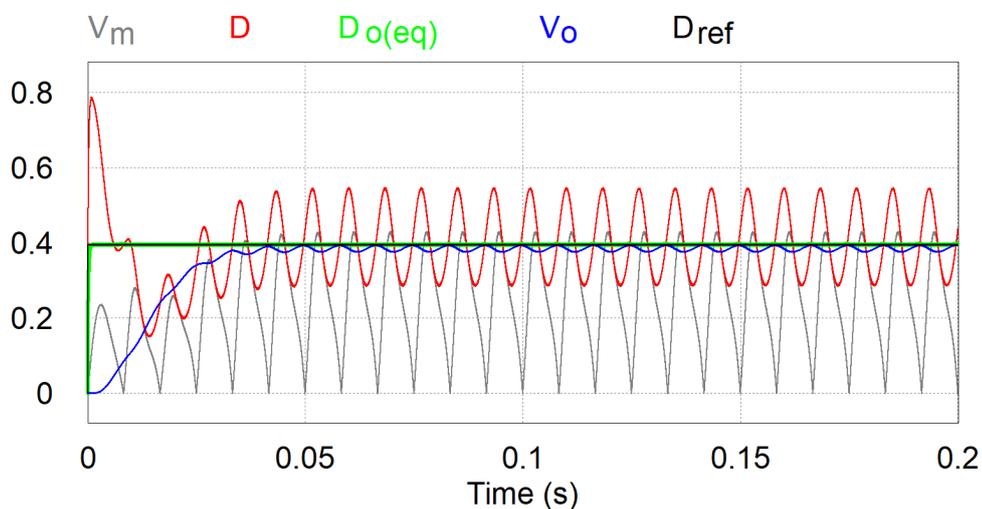


Fonte: Autoria própria - Simulador PSIM.

#### 4.5 ANÁLISE DE DESEMPENHO

A função de ativação e o algoritmo para taxa de aprendizado dinâmica têm grande relevância neste trabalho, em virtude de que o ANNC é de tempo real e, portanto, precisa garantir que as redes neurais utilizadas apresentem desempenho ao ponto de possibilitar ajustes dos pesos com alta taxa de acerto. Diante disso tanto o RMSProp, quanto a função de ativação ELU, serão abordados com mais detalhes no que diz respeito ao desempenho do ANNC.

Figura 33 – Fator de correção de 0.4 aplicado a  $V_m$  para o primeiro ciclo de  $V_{ac}$ . Valor médio de  $D$  atua no ajuste da amplitude de  $V_m$ . A característica ondulatório de  $D$  aplica deformação na forma do sinal de  $V_m$  para corrigir  $I_{ac}$  implicando num FP próximo da unidade.  $V_o$  encontra-se normalizado no intervalo [0 1].



Fonte: Autoria própria - Simulador PSIM.

#### 4.5.1 ALGORITMO

A apresentação do algoritmo do ANNC no que diz respeito a atualização da razão cíclica em tempo real encontra-se na Figura 34, o qual trata de uma adaptação do algoritmo desenvolvido na Seção 2.5. De sorte que as entradas do ANNC são atualizadas se, e somente se, a Energia do Erro for menor que o limiar de aprendizado, identificado pela variável *threshold* (Tabela 4).

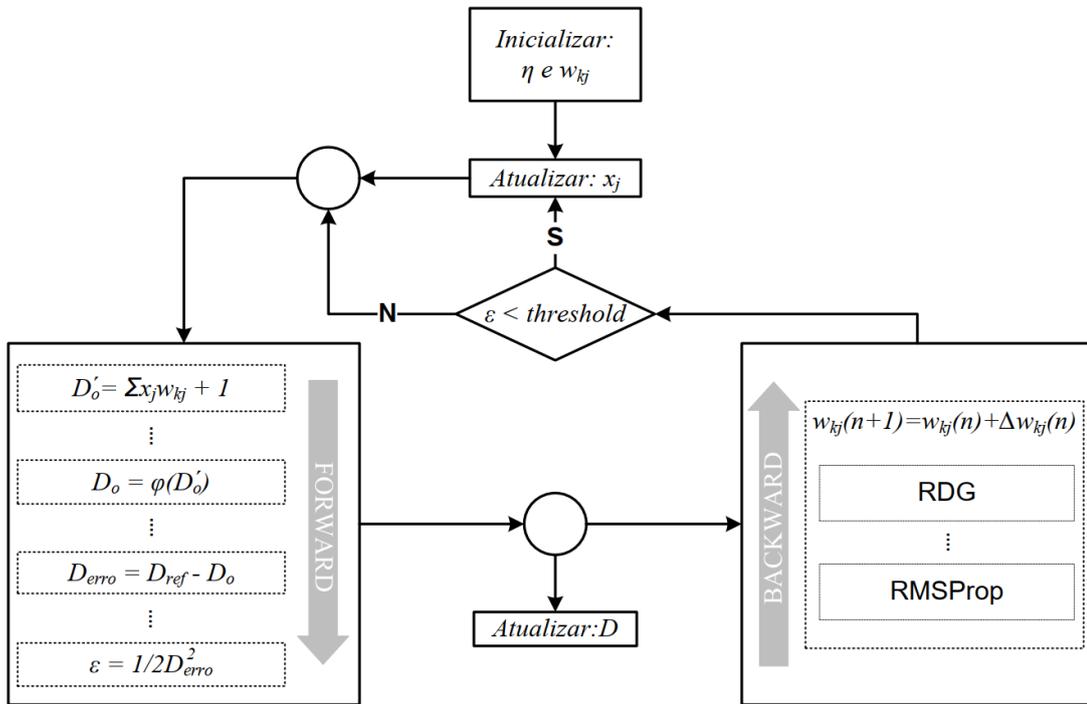
#### 4.5.2 TAXA DE APRENDIZADO DINÂMICA COMO FATOR DE DESEMPENHO

Os gráficos desta seção foram desenvolvidas a partir da RNA Monocamada, tendo em vista que esta representa a arquitetura mais dependente do RMSProp no diz respeito ao desempenho.

As curvas contidas nos gráficos das Figuras 35, 36 e 37, representam a resposta do ANNC para a função de ativação ELU diante de três cenários distintos no que diz respeito a atualização da taxa de aprendizado:

1. No cenário da Figura 35 o ANNC encontra-se configurado com taxa de aprendizado fixa. Todos os pesos da rede, incluindo o *bias*, possuem a mesma taxa de aprendizado e seu valor é fixado previamente.
2. ANNC com taxa de aprendizado dinâmica:

Figura 34 – Algoritmo referente ao ANNC. Onde se lê  $x_j w_{kj}$ , corresponde aos parâmetros anteriores a camada de saída.



Fonte: Autoria própria.

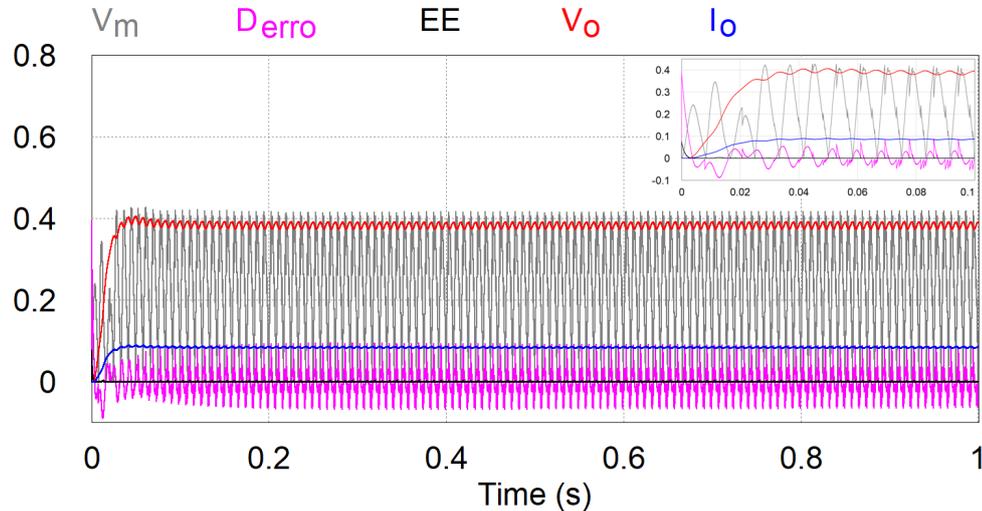
- a. Utilização do algoritmo RMSProp com a mesma taxa de aprendizado tanto para o *bias* quanto para os demais pesos da rede é apresentada no cenário da Figura 36.
- b. Utilização do algoritmo RMSProp com taxa de aprendizado individualizada para o *bias* é apresentada no cenário da Figura 37, onde a atualização do *bias* é independente dos demais pesos da RNA.

Em todas as configurações do ANNC pertinentes a taxa de aprendizado dinâmica, o resultado do controle para os valores de  $V_o$  e  $I_o$  consideraram irrelevante o tipo da taxa de aprendizado, contudo não se pode afirmar o mesmo se o ponto de observação for a corrente de entrada,  $I_{ac}$ .

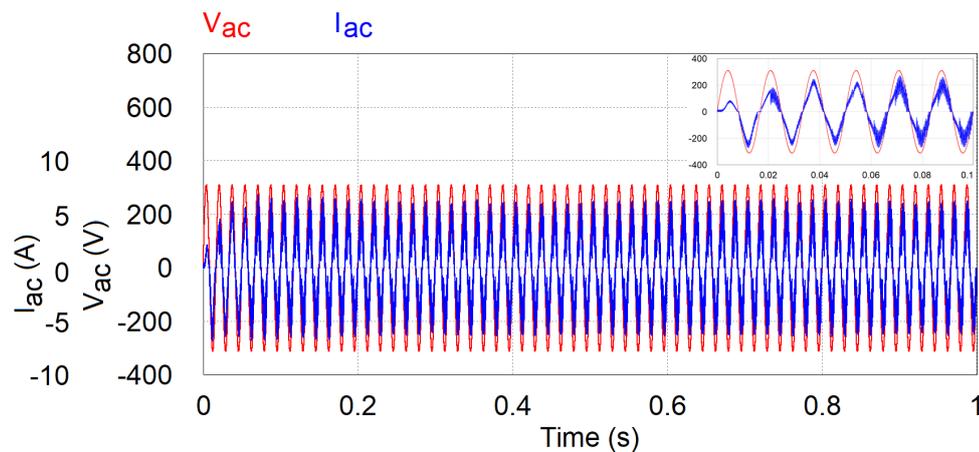
Dois aspectos que servem de diretriz para medir o desempenho de uma rede neural são, os parâmetros internos  $D_{erro}$  e a Energia do Erro (EE), os quais devem apresentar poucas variações na medida que o aprendizado da rede neural ocorre. Nas formas de onda da Figura 35, fica evidente a distorção da razão cíclica modulante,  $V_m$ , a qual é diretamente afetada pela instabilidade na razão cíclica constante,  $D$ , o que promove à distorção em  $I_{ac}$ .

Na Figura 36 também se observa certa instabilidade no processamento da RNA, o que fica claro quando se examina a Energia do Erro, afetando negativamente a corrente de entrada e, conseqüentemente, o FP. Porém, a distorção em  $V_m$  é menos acentuada e não generalizada se considerado o exposto na Figura 35.

Figura 35 – Resposta do ANNC com taxa de aprendizado fixa. ANNC não consegue corrigir o erro,  $D_{erro}$ , ao longo de todo o período de processamento e, portanto, a Energia do Erro apresenta oscilações acentuadas. Destaca-se a legenda com amostra entre 0 e 100 ms.  $V_o$  e  $I_o$  encontram-se normalizados no intervalo [0 1].



(a) Distorção generalizada em  $V_m$  é consequência dos ajustes inadequados dos parâmetros da rede neural.



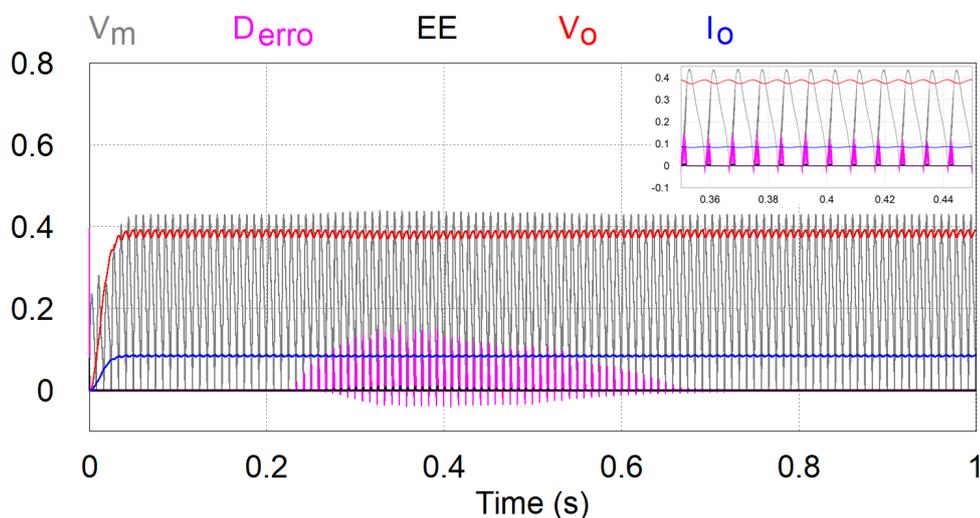
(b) Deformação observada em  $I_{ac}$  devido às alterações em  $V_m$ .

Fonte: Autoria própria - Simulador PSIM.

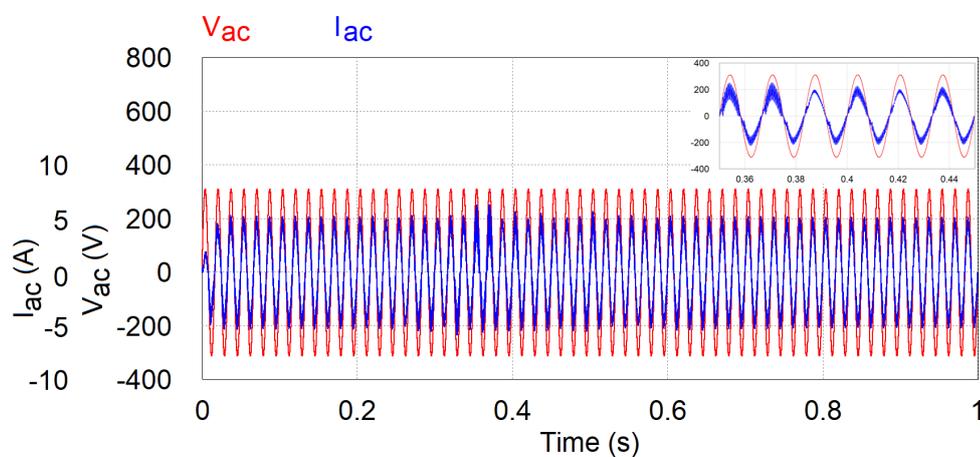
A informação ilustrada nas curvas apontadas nas Figuras 36 e 37, em especial para  $V_m$  e  $I_{ac}$ , confirmam a premissa de que o algoritmo RMSProp representa uma solução interessante a respeito da atualização da taxa de aprendizado dinâmica. No entanto, a aplicação do RMSProp de forma independente para o bias mostrou-se mais adequada que a forma generalizada.

Portanto, é possível afirmar, com base nos dados, que o ANNC com ajuste dinâmico da taxa de aprendizado por parte do algoritmo RMSProp, com independência para o ajuste do *bias* em contrapartida dos demais pesos da RNA, mostrou-se mais eficaz.

Figura 36 – Resposta do ANNC com taxa de aprendizado dinâmica, com utilização do algoritmo RMSProp gerando a mesma taxa de aprendizado tanto para o *bias* quanto para os demais pesos da rede. ANNC apresenta instabilidade entre 220 e 680 ms e não consegue corrigir o erro,  $D_{erro}$ , durante essa fatia do processamento e, portanto, a Energia do Erro apresenta oscilações. Destaca-se a legenda com amostra entre 350 e 450 ms.  $V_o$  e  $I_o$  encontram-se normalizados no intervalo [0 1].



(a) Distorção localizada em  $V_m$  é consequência dos ajustes inadequados dos parâmetros da rede neural.



(b) Deformação pontual observada em  $I_{ac}$  devido às oscilações em  $V_m$ .

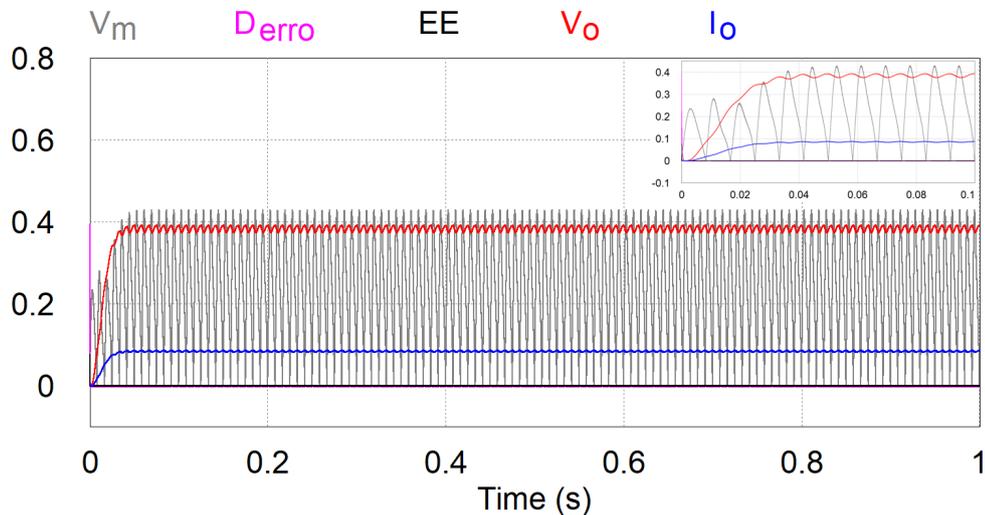
Fonte: Autoria própria - Simulador PSIM.

### 4.5.3 TAXA DE APRENDIZADO DINÂMICA INDEPENDENTE APLICADA A RNA MULTICAMADA

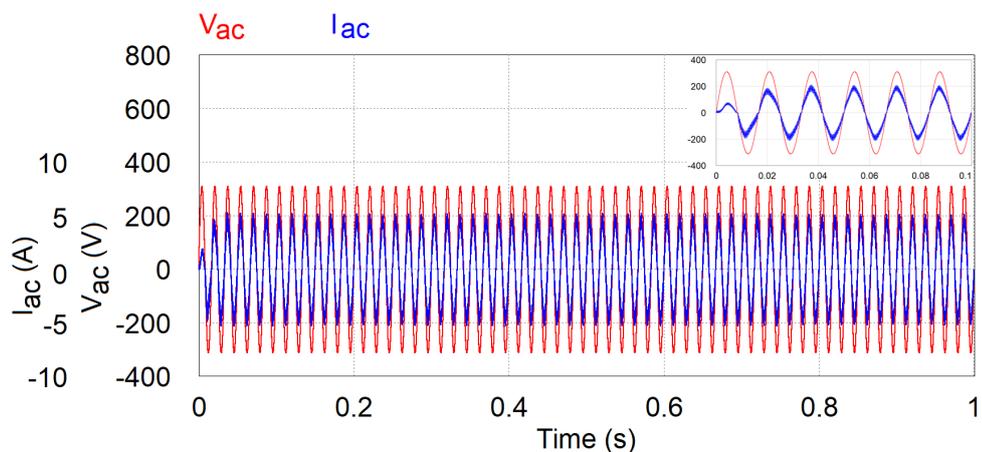
Um fator importante que deve ser avaliado em relação a aplicação do algoritmo RMS-Prop a uma rede neural do tipo MLP é a questão da independência do ajuste da taxa de aprendizado para o *bias* e os demais pesos da rede, onde no cenário da Seção 4.5.2 mostrou-se extremamente positivo. Porém, segundo Haykin (2001), existem ressalvas a serem verificadas no que diz respeito as arquiteturas do tipo MLP.

De acordo com Haykin (2001), todos os neurônios de uma rede neural de múltiplas

Figura 37 – Resposta do ANNC com taxa de aprendizado dinâmica. Utilização do algoritmo RMSProp com taxa de aprendizado individualizada para o *bias*. Não se observa oscilações nos parâmetros do ANNC e nem nos do Buck. Destaca-se a legenda com amostra entre 0 e 100 ms.  $V_o$  e  $I_o$  encontram-se normalizados no intervalo [0 1].



(a) Não se observa distorção em  $V_m$ .



(b) Não se observa deformação em  $I_{ac}$ .

Fonte: Autoria própria - Simulador PSIM.

camadas devem aprender com a mesma taxa de aprendizado. A exceção a tal regra gira em torno das últimas camadas, haja visto que estas apresentam gradientes locais maiores e podem, portanto, receber valores menores de aprendizado. Sendo assim, como a arquitetura MLP foi arbitrada com apenas uma camada oculta e manteve a vantagem observada na Seção 4.5.2 quanto a independência na taxa de atualização do *bias* frente aos demais pesos da rede, o *bias* das camadas oculta e de saída possuem seu peso atualizado de maneira independente.

#### 4.5.4 INFLUÊNCIA DO NÚMERO DE NEURÔNIOS NA TAXA DE APRENDIZADO DINÂMICA

As curvas encontradas nos gráficos das Figuras 38, 39 e 40 demonstram a atualização da taxa de aprendizado,  $\eta$ , para o *bias* e para os demais pesos das RNAs aplicadas ao ANNC. Observa-se pela comparação entre os dados apresentados nas figuras que, de acordo com o número de camadas, ao longo do processamento, a rede neural com maior volume de neurônios (nós) apresenta-se mais uniforme no que diz respeito ao ajuste da taxa de aprendizado. As diferenças apresentadas entre os cenários não impactam nas características de operação do Buck PFC, em todas as configurações o conversor operou com  $FP$  e  $V_o$  próximos de suas referências,  $FP \approx 1$  e  $V_o \approx 60 V$ .

Do ponto de vista da operação em tempo real, os resultados avaliados na Figura 38 (apenas 1 nó de processamento) em detrimento aos das Figuras 39 e 40 (3 e 5 nós de processamento) não influenciam negativamente no funcionamento do Buck PFC. Porém, da perspectiva da computação exigida, pode representar demanda extra de *hardware*, o que deve ser observado com cuidado ao considerar a plataforma de desenvolvimento do protótipo.

De acordo com Haykin (2001), a priori, uma RNA com menor volume de nós de processamento exigiria menos poder de processamento, o que representa uma vantagem diante de uma implementação física. Os cenários das Figuras 39 e 40, não apresentam diferença no controle dos parâmetros do Buck PFC, o que, segundo Haykin (2001), justifica a escolha da RNA com apenas três nós de processamento para a camada oculta em uma aplicação em tempo real.

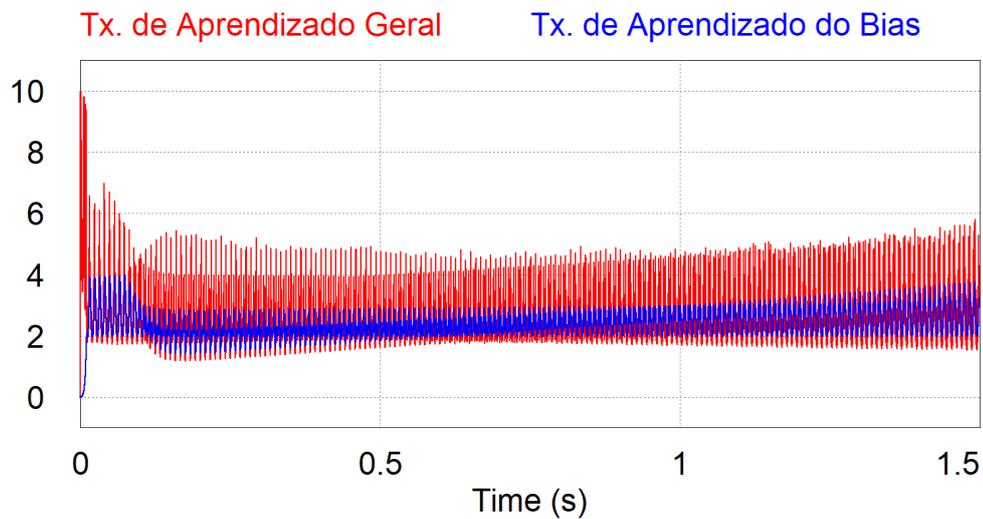
Outro ponto que pode ser considerado, por exemplo, em um projeto que a plataforma de *hardware* não represente um fator limitante, explorar uma RNA com maior número de neurônios na camada oculta, quiçá ampliar o número de camadas ocultas, pode representar um ganho de desempenho, haja visto que a atualização das taxas de aprendizado tendem a estabilizar, como se observa a partir de 900 *ms* no cenário da Figura 40.

#### 4.6 INFLUÊNCIA DA FUNÇÃO DE ATIVAÇÃO NO DESEMPENHO

Como discorrido no Capítulo 2, especificamente na Seção 2.2, sobre as propriedades das funções de ativação, conta que a função de ativação ELU apresenta características que podem acelerar o aprendizado em redes neurais e conduzir o algoritmo para um alto nível de precisão com menor número de iterações. Como o objetivo dessa seção é avaliar o desempenho da função de ativação, os cenários das Figuras 41, 42 e 43 se diferenciam apenas pela aplicação do tipo desta função, o que envolve as funções ELU e Logística padrão.

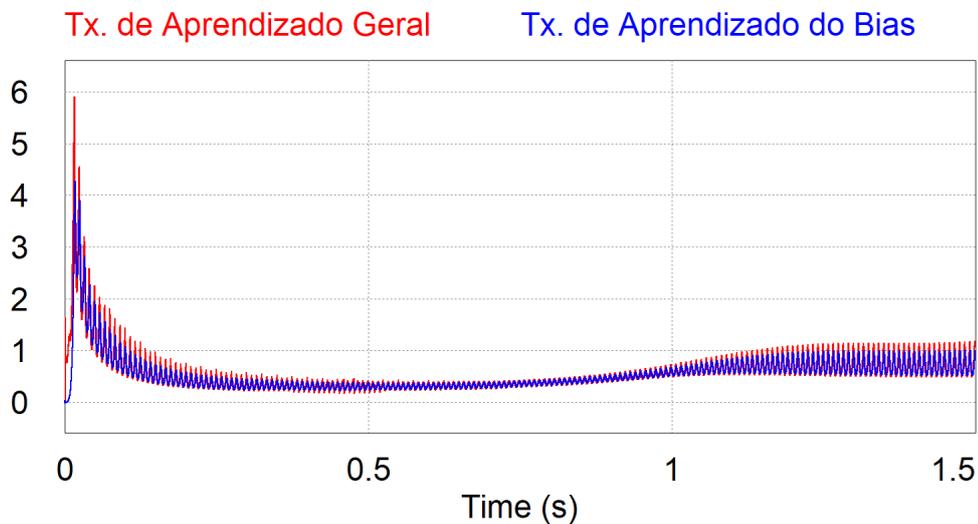
A geração dos gráficos ilustrados nas Figuras 41, 42 e 43 foi desenvolvido sob o prisma da arquitetura Monocamada, com intervalo de análise entre 0 a 600 *ms*, considera os mesmos parâmetros de entrada e empregam o algoritmo RMSProp com taxa de aprendizado individualizada para o *bias*.

Figura 38 – Evolução das taxas de aprendizado para o *bias* e os demais pesos da rede para a arquitetura monocamada.



Fonte: Autoria própria - Simulador PSIM.

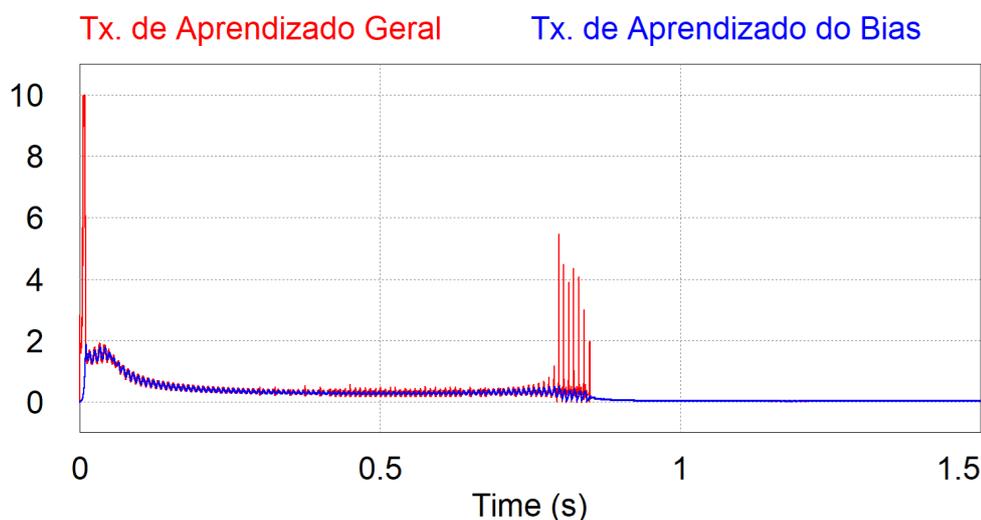
Figura 39 – Evolução das taxas de aprendizado para o *bias* e os demais pesos da rede para a arquitetura MLP com três neurônios na camada oculta.



Fonte: Autoria própria - Simulador PSIM.

Nos cenários apontados pelas Figuras 41(a) e 41(b) são avaliados o erro,  $D_{erro}$ , entre a razão cíclica equivalente,  $D_{o(eq)}$ , e a razão cíclica de referência,  $D_{ref}$ . De posse dos gráficos apresentado pela Figura 41(a), o qual opera segunda a função de ativação Logística, percebe-se diversas anomalias em  $D$  devido a correção inadequada dos parâmetros internos do ANNC por parte da função de ativação, o que pode ser averiguado pelas constantes alterações na Energia do Erro,  $EE$ . Em contrapartida não se observa o mesmo para o cenário da Figura 41(b), onde

Figura 40 – Evolução das taxas de aprendizado para o *bias* e os demais pesos da rede para a arquitetura MLP com cinco neurônios na camada oculta.



Fonte: Autoria própria - Simulador PSIM.

a função de ativação trata da ELU.

A deformação na razão cíclica modulante,  $V_m$ , apontada no gráfico da Figura 42(a), é o reflexo do que se observa no cenário descrito pela Figura 41(a) devido a atuação da função Logística na atualização dos parâmetros do ANNC, em especial os pesos da rede neural associada ao controlador. Contudo, quando se considera o cenário atribuído à Figura 42(b), uma vez que a função de ativação trata da ELU, os parâmetros do ANNC são ajustados adequadamente, o que corrobora para  $D_{o(eq)}$  constante e praticamente igual a  $D_{ref}$ .

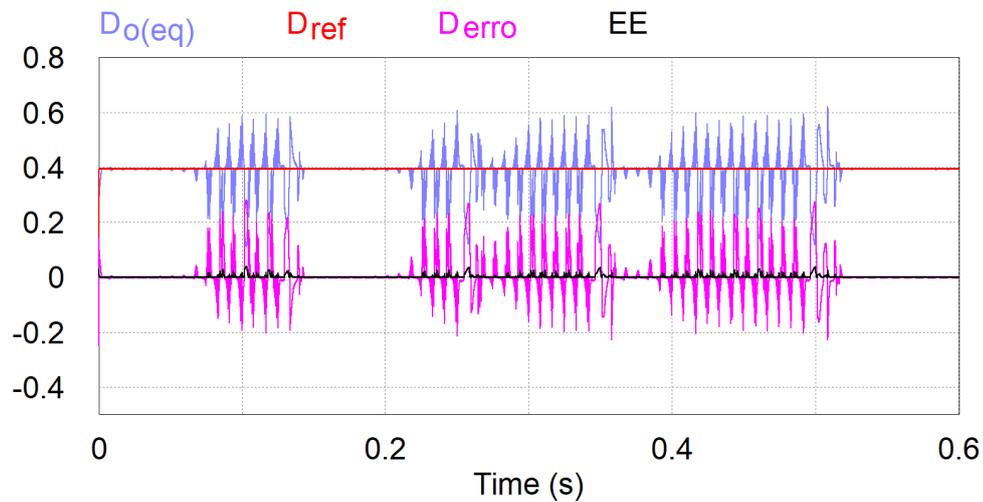
Nos cenários apontado pelos gráficos da Figura 43 têm-se amostras da corrente e da tensão de entrada do retificador Buck PFC. A distorção vista no gráfico de  $I_{ac}$  denotado na Figura 43(a) é fruto da inadequação da atualização dos pesos da rede neural associada ao ANNC, que influencia negativamente no FP. Contudo, na Figura 43(b) não se observa tal deformação, por conseguinte o FP não é afetado, de sorte que o gráfico desta figura tem como base a função de ativação ELU.

A priori, com base nos resultados gerados a partir das funções de ativação Logística e ELU, pode-se afirmar que o desempenho apresentado pela função ELU mostrou-se extremamente superior se comparado com os da Logística.

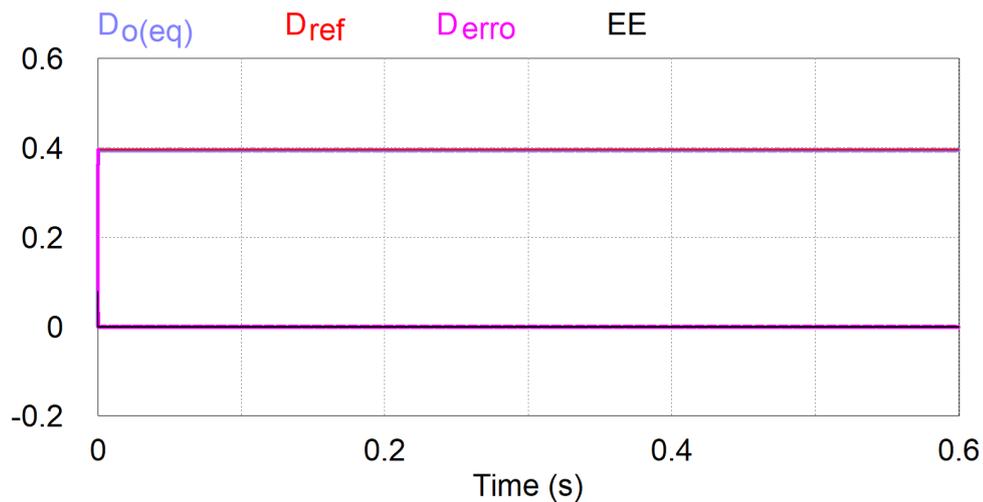
#### 4.7 MÉTRICAS DE DESEMPENHO DAS FUNÇÕES DE ATIVAÇÃO

Na Seção 4.6, de acordo com os dados apresentados, pôde-se inferir que o ANNC dotado de uma rede neural com aprendizado baseado na função de ativação ELU mostrou-se mais promissor que a arquitetura apoiada na função Logística contudo, a solução não traz uma medida quantitativa da eficiência de uma solução frente a outra.

Figura 41 – Resposta do ANNC monocamada para o cenário em que são comparadas as atualizações das razões cíclicas a partir das funções de ativação Logística e ELU.



(a) Logística: Atualização da razão cíclica,  $D$ , promove erro,  $D_{erro}$ , entre  $D_{o(eq)}$  e  $D_{ref}$  acentuado, aponta para ajuste inadequado dos pesos da rede.



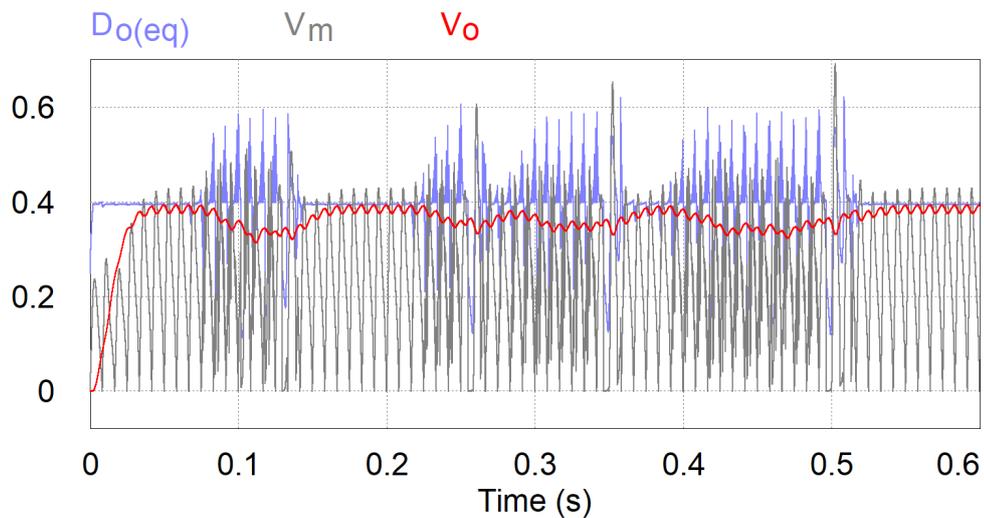
(b) ELU: Atualização da razão cíclica,  $D$ , para um erro entre  $D_{o(eq)}$  e  $D_{ref}$  que pode ser considerado desprezível no ajuste dos pesos da rede.

Fonte: Autoria própria - Simulador PSIM.

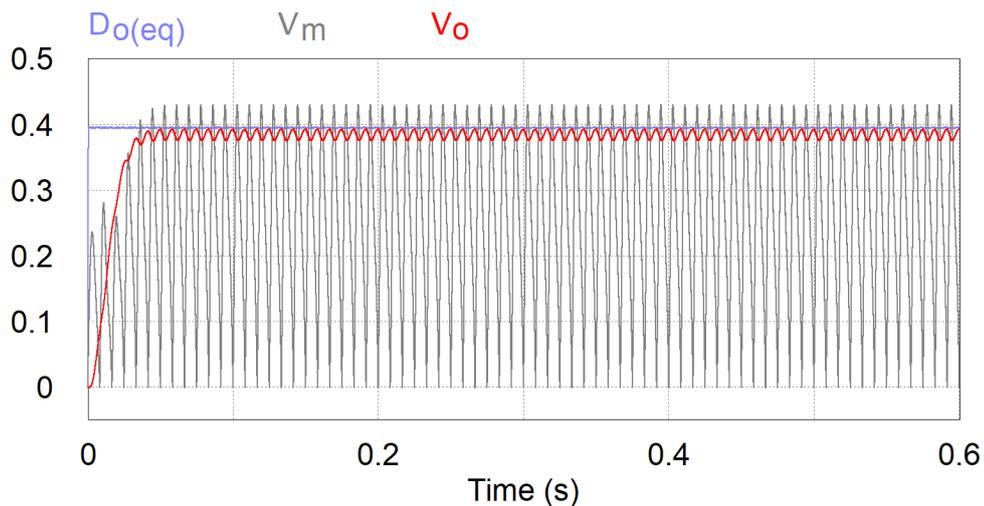
Para avaliar o desempenho de um modelo existem diversas maneiras, as quais partem da premissa da organização dos dados entre conjuntos de treinamento e de teste, com o objetivo de obter estimativas do poder preditivo do modelo, dentre elas destaca-se as técnicas *K-Fold Cross Validation*, *Hold Out*, *Bootstrap*, *Receiver Operating Characteristics (ROC)*, etc (MITCHELL, 1997; FAWCETT, 2006). Todavia, pelo fato do ANNC operar em tempo real tais técnicas não se aplicam diretamente, haja visto que o ANNC não é caracterizado a partir de conjuntos distintos de dados, ou seja, que possam ser distribuídos entre teste e validação.

Ainda assim pode-se medir o fator preditivo relativo ao ANNC, e algumas métricas que envolvem medidas de qualidade podem ser aplicadas ao controlador sem perda de generalidade. Para tal evidencia-se o erro e a acurácia, onde a acurácia é o complemento do erro, e encontram-

Figura 42 – Reflexo da atualização da razão cíclica  $D$  sobre  $V_m$  e  $V_o$  considerando as funções de ativação Logística de ELU.  $V_o$  encontra-se normalizada no intervalo  $[0\ 1]$ .



(a) Logística: Alterações na razão cíclica,  $D$ , promove deformações na razão cíclica modulante,  $V_m$ , provocando variações acentuadas em  $V_o$ .



(b) ELU: A razão cíclica,  $D$ , não promove deformações na razão cíclica modulante,  $V_m$ , refletindo estabilidade em  $V_o$ .

Fonte: Autoria própria - Simulador PSIM.

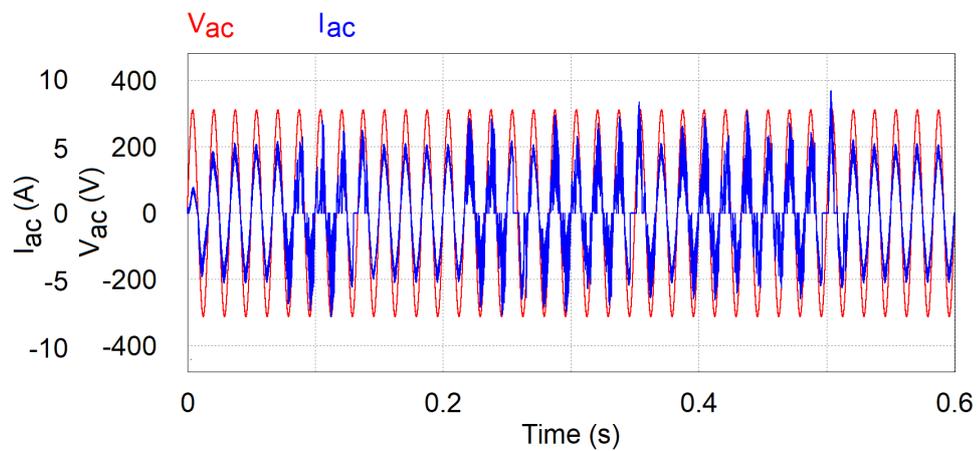
se determinados pelas Equações (47a) e (47b).

$$\text{Métricas de Desempenho} = \begin{cases} \text{Erro} = \left\{ \begin{array}{l} \text{Num. de Erros/Num. de Objetos} \end{array} \right. & (47a) \\ \text{Acurácia} = \left\{ \begin{array}{l} \text{Num. de Acertos/Num. de Objetos} \end{array} \right. & (47b) \end{cases}$$

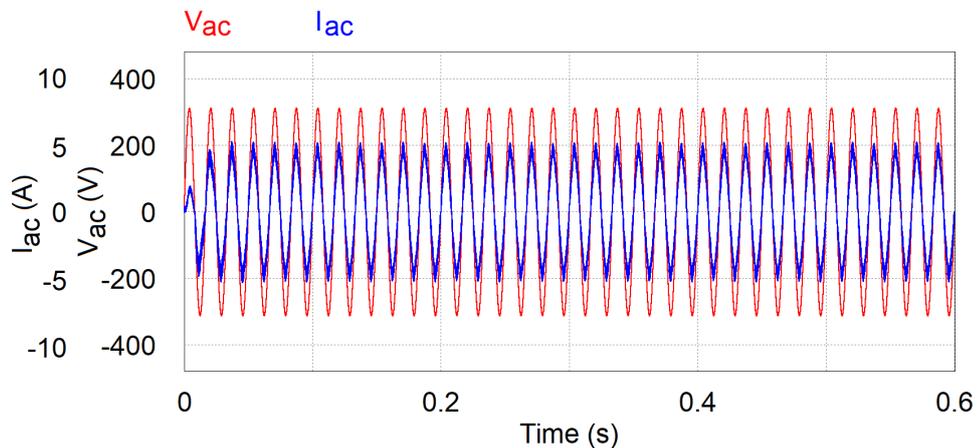
Ao aplicar as medidas de erro e de acurácia ao ANNC considera-se três pontos:

1. O *número de erros* trata do somatório das amostras que tiveram seus valores superiores ao limiar de ativação (*threshold*) e o *número de acertos* considera os valores inferiores ao limiar de ativação.

Figura 43 – Atualização da razão cíclica,  $D$ , reverbera negativamente na forma da corrente de entrada,  $I_{ac}$ , para as funções de ativação Logística e ELU.



(a) Logística: Resposta do ANNC para a função de ativação Logística apresenta diversas deformações em  $I_{ac}$ .



(b) ELU: Resposta do ANNC para a função de ativação ELU não apresenta alterações em  $I_{ac}$ .

Fonte: Autoria própria - Simulador PSIM.

2. O problema relativo ao ANNC não infere diferença de importância entre os erros e os acertos, nem tão pouco há distinção entre os erros ocorridos devida ao tipo da função de ativação.
3. Ainda que as medidas de erro e acurácia são comumente aplicadas a problemas separados por classes, no contexto do ANNC observou-se que sua aplicação alcançou bons resultados.

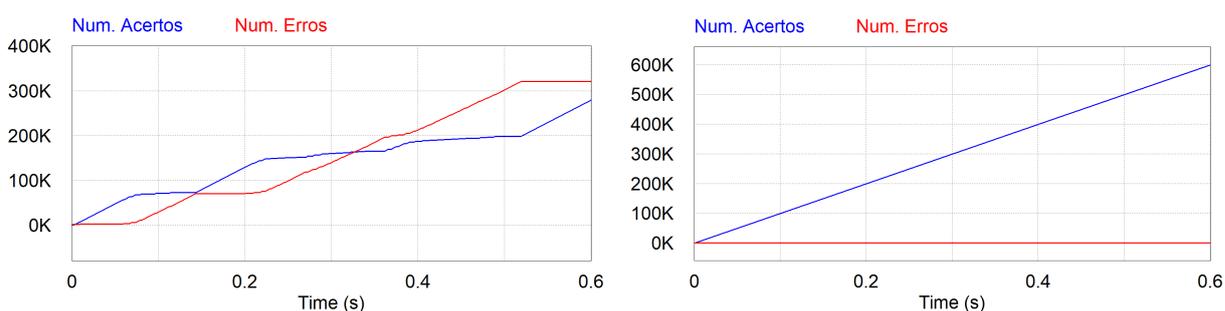
Sendo assim a análise dos dados contidos na Tabela 2 e dos gráficos da Figura 44 confirmam o aventado inicialmente na Seção 4.6, que a função de ativação ELU é mais adequada para o ANNC que a função Logística.

Tabela 2 – Medidas da qualidade do fator preditivo que relaciona as funções de ativação Logística e ELU associadas ao ANNC.

Função de Ativação	Num. Acertos	Num. Erros	Erro	Acurácia	Num. Amostras
Logística	279405	320595	53.4325%	46.5675%	600000
ELU	599257	743	0.1238%	99.8762%	600000

Fonte: Autoria própria.

Figura 44 – Análise de qualidade do fator preditivo para as funções Logística e ELU.



(a) Logística: Percebe-se constantes oscilações a atuação da função Logística.

(b) ELU: Fica claro no exemplo a estabilidade no aprendizado baseado na função ELU.

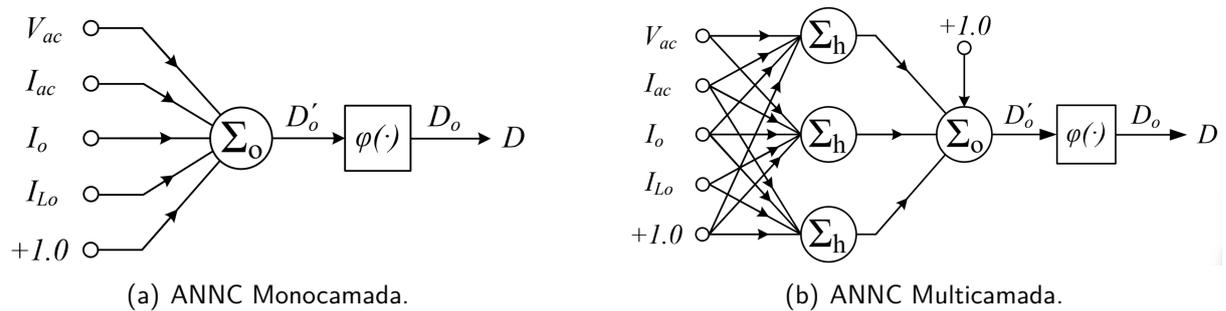
Fonte: Autoria própria - Simulador PSIM.

#### 4.8 ARQUITETURA DAS RNAS APLICADAS AO ANNC

No que diz respeito ao processamento das RNAs no contexto da simulação numérica, a definição da quantidade de nós, haja visto que o processamento em tempo real não preconiza memória, e que o modelo neuronal utiliza algoritmo para taxa de aprendizado dinâmica, o número dos nós de processamento das redes foi explorado tendo por base as RNAs apresentadas no Capítulo 2 e citadas a seguir:

1. Para o ANNC baseado na RNA monocamada com apenas um nó de processamento, o número de nós segue o oferecido pela arquitetura, ou seja, apenas um nó de processamento, o qual encontra-se identificada pelo subscrito  $o$ . Já a camada de entrada é composta de cinco nós sensoriais. A Figura 45(a) apresenta a RNA monocamada associada ao ANNC.
2. Ao que tange a RNA multicamada, a arquitetura do ANNC foi definida de modo a considerar o Teorema da Aproximação Universal e, portanto, a rede possui apenas uma única camada oculta. Como o objetivo central é o de demonstrar a generalidade do método, o número mínimo de nós foi arbitrado da seguinte maneira: A camada de entrada consta de 5 nós sensoriais, a camada oculta foi configurada com 3 nós de processamento (como o exposto na Seção 4.5.3 pelas Figuras 39 e 40), a qual encontra-se identificada pelo subscrito  $h$ , e a camada de saída com apenas 1 nó, identificada pelo subscrito  $o$ , como consta na Figura 45(b).

Figura 45 – Arquiteturas propostas para o ANNC.



Fonte: Autoria própria.

#### 4.9 CONCLUSÃO

Aplicadas as técnicas de controle propostas para o Buck PFC, como o neurônio aditivo e o retorno da corrente do indutor de saída, as quais adicionam a condição temporal necessária para a correção dos pesos da rede neural associada ao ANNC em tempo real. Considera-se, de posse dos resultados, que a modelagem do ANNC, com destaque para a taxa de aprendizado dinâmica e correção do *bias* independente dos demais pesos da rede neural, bem como a função de ativação ELU, alcançou o seu objetivo pois, replicou os efeitos do trabalho proposto por F Pottker Souza e Barbi (1999) para o mesmo retificador.

## 5 PROJETO E SIMULAÇÃO

Este capítulo se divide em duas frentes, a primeira descreve o projeto e o dimensionamento do conversor Buck PFC, a segunda retrata os resultados obtidos segundo as simulações.

### 5.1 PROJETO E DIMENSIONAMENTO

O retificador Buck desenvolvido para este estudo trata de uma releitura do trabalho apresentado por F Pottker Souza e Barbi (1999), dessa forma os dados a seguir consideram o que se encontra descrito no texto original, de modo que na Tabela 3 consta das especificações do projeto.

Tabela 3 – Especificações para o projeto do retificador Buck PFC.

$V_{ac(pico)}$ [V]	$f(linha)$ [Hz]	$P_{o(máx)}$ [W]	$P_{o(min)}$ [W]	$I_{o(máx)}$ [A]	$I_{o(min)}$ [A]	$f_s$ [kHz]	$V_o$ [V]	$\Delta V_o$ [V]
311	60	1500	750	25	12,5	30	60	6

Fonte: Adaptado de (SOUZA, F. P.; BARBI, 1999)

Para o dimensionamento do indutor de saída, parte-se da restrição que é observada para a corrente  $I_{L_o}$ , onde o valor mínimo desta deve ser, sempre, superior ao valor absoluto da corrente de entrada,  $I_{ac}$ , para um ângulo  $\theta$ . Atendida a restrição relativa a  $I_{L_o}$  frente a  $I_{ac}$ , a proposta do método é minimizar a distorção da corrente de entrada para que se obtenha um FP próximo ao unitário.

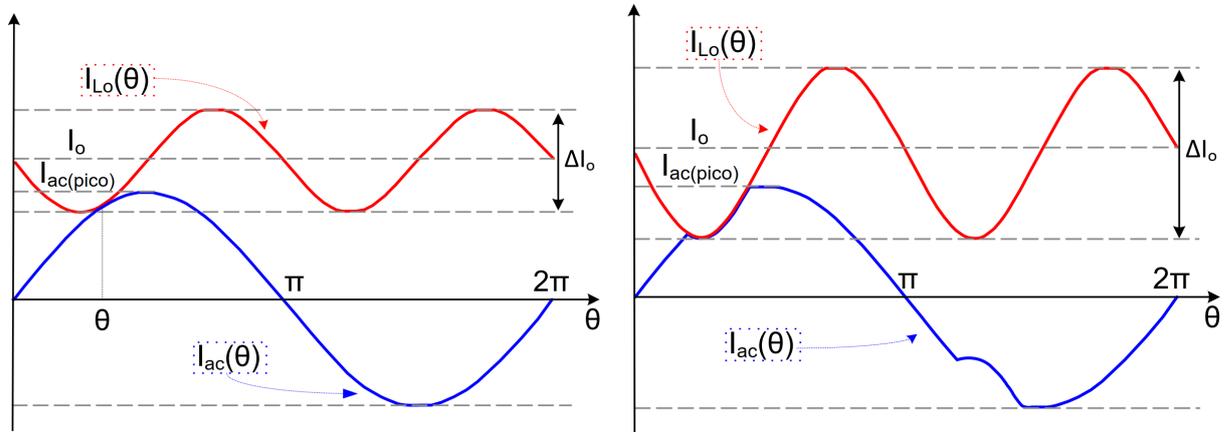
A Figura 46(a) ilustra o comportamento da corrente sobre o indutor  $L_o$  para a condição em que a restrição para  $I_{L_o}$  é atendida, de modo que  $\theta$  representa o ponto onde as correntes se tocam. Por outro lado têm-se na Figura 46(b) a restrição para  $I_{L_o}$  não cumprida.

A corrente de entrada é calculada de acordo com a Equação (48) para os seus valores máximos e mínimos. O cálculo de  $I_{ac(pico)}$  é necessário pois índice de modulação encontra-se em função desta corrente.

$$I_{ac(pico)} = \frac{2 \cdot P_o}{V_{ac(pico)}} \therefore \begin{cases} I_{ac(pico),máx} = \frac{2 \cdot P_{o(máx)}}{V_{ac(pico)}} = \frac{2 \cdot 1500}{311} = 9,65 \text{ A} \\ I_{ac(pico),min} = \frac{2 \cdot P_{o(min)}}{V_{ac(pico)}} = \frac{2 \cdot 750}{311} = 4,82 \text{ A} \end{cases} \quad (48)$$

Para o cálculo de  $M$  têm-se o apontado pela Equação (49), o que está de acordo com o valor ilustrado na Figura 47. O índice de modulação marca a localização do ângulo  $\theta$ , no qual as correntes,  $I_{ac}$  e  $I_{L_o}$ , se tocam por apenas um ponto, que é dado pela relação de ambas as correntes.

Figura 46 – Ondulação da corrente sobre  $L_o$ .



(a) Limite para a ondulação de  $I_{L_o}$  sem distorção de  $I_{ac}$ . (b) Ondulação de  $I_{L_o}$  além do limite, distorção em  $I_{ac}$ .

Fonte: Adaptado de (SOUZA, F. P.; BARBI, 1999)

$$M = \frac{I_{ac(pico)máx}}{I_{O(máx)}} = \frac{I_{ac(pico)min}}{I_{O(min)}} = \frac{9,65}{25} = 0,386 \quad (49)$$

Para se determinar o indutor de saída é necessário, em primeira mão, encontrar o ângulo  $\theta$ , o qual, segundo a aplicação da Equação (50), chega-se ao gráfico apresentado na Figura 47, que representa a variação  $\Delta\theta$  em função de  $\Delta M$ , onde encontra-se em destaque o valor de  $\theta \approx 50^\circ$ , para  $M = 0,386$ .

$$\frac{d}{d\theta} \Delta I_{Or} = \frac{2(-\text{sen}(2\theta)M \cos(\theta) - 2(1 - M \text{sen}(\theta) \cos(2\theta)))}{[\text{sen}(2\theta)]^2} = 0 \quad (50)$$

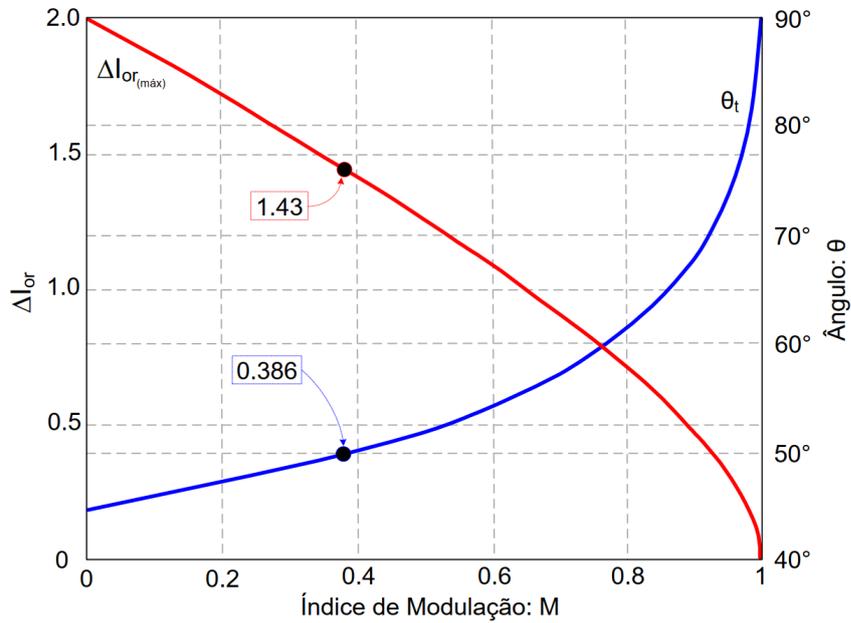
Também é necessário conhecer a variação da ondulação relativa da corrente de saída,  $\Delta I_{Or}$ , bem como seu valor máximo dado por  $\Delta I_{Or(máx)}$ , a sua variação absoluta, dada por  $\Delta I_o$ , para encontrar o valor de  $L_o$ , o que se observa a partir das Equações (51) e (52). Ressalta-se que a máxima ondulação ocorre para o limite inferior da potência do sistema, o que fica a caráter de  $I_{O(min)}$  que, segundo a Tabela 3, é igual a 12,5 A. Na Figura 47 é possível observar a curva que relaciona  $\Delta M$  e  $\Delta I_{Or}$ , com destaque para  $\Delta I_{Or(máx)} = 1,43$ .

$$\Delta I_{Or(máx)} = 2 \cdot \left( \frac{1 - M \text{sen}(\theta_t)}{\text{sen}(2\theta_t)} \right) = 2 \cdot \left( \frac{1 - 0,386 \cdot \text{sen}(50^\circ)}{\text{sen}(2 \cdot 50^\circ)} \right) = 143 \% \quad (51)$$

$$\Delta I_o = \Delta I_{Or(máx)} \cdot I_{O(min)} = 1,43 \cdot 12,5 = 17,9 \text{ A} \quad (52)$$

De posse dos resultados para a corrente de ondulação sobre  $L_o$ , haja visto que  $\Delta V_o$  foi estipulado previamente e encontra-se definido na Tabela 3, é possível calcular os valores mínimos para  $L_o$  e  $C_o$  de acordo com as Equações (53) e (54).

Figura 47 – Relação entre o índice de modulação,  $M$ , e duas outras grandezas, o ângulo,  $\theta$ , e a ondulação relativa da corrente de saída,  $\Delta I_{or}$ .



Fonte: Adaptado de (SOUZA, F. P.; BARBI, 1999)

$$L_{o(min)} = \frac{P_{o(máx)}}{2\pi f_{(linha)} I_o \Delta I_o} = \frac{1500}{2 \cdot \pi \cdot 60 \cdot 25 \cdot 17,9} = 8,9 \text{ mH} \quad (53)$$

$$C_{o(min)} = \frac{\Delta I_o}{4\pi f_{(linha)} \Delta V_o} = \frac{17,9}{4 \cdot \pi \cdot 60 \cdot 6} = 4,3 \text{ mF} \quad (54)$$

Os valores para  $L_f$  e  $C_f$ , que compõem o filtro  $LC$  de entrada, os quais são dimensionados para filtrar a frequência de chaveamento, podem ser encontrados pelo método a seguir:

1. Encontra-se a frequência de corte do filtro, a qual considera 10% do valor da frequência de chaveamento, o que neste caso seria  $f_c = 3 \text{ kHz}$ , haja visto que  $f_s = 30 \text{ kHz}$ :

$$f_c = \frac{f_s}{10} = 3 \text{ kHz} \therefore \omega_c = 18850 \text{ rad/s}$$

2. A posteriori encontra-se a resistência equivalente observada pela entrada dada a potência máxima desprendida pelo sistema:

$$R_{eq} = \frac{V_{ac(pico)}}{I_{ac(pico)máx}} = \frac{311}{9,65} = 32,24 \text{ } \Omega \quad (55)$$

3. Encontrado  $R_{eq}$  e  $\omega_c$  é possível determinar os valores dos componentes,  $C_f$  e  $L_f$ , de acordo com as Equações (56) e (57). Deve-se considerar para os cálculos  $\zeta = 1,0$ :

$$C_f = \frac{1}{R_{eq} 2\zeta \omega_c} = \frac{1}{32,24 \cdot 2 \cdot 1 \cdot 18850} \approx 0,8 \text{ } \mu\text{F} \quad (56)$$

$$L_f = \frac{1}{\omega_c^2 C_f} = \frac{1}{18850^2 \cdot 0,8} \approx 3,5 \text{ mH} \quad (57)$$

4. De posse dos valores de  $C_f$  e  $L_f$ , considerando os aspectos da simulação, promove-se um ajuste ao filtro  $LC$ :

$$\text{Ajuste em } LC : \begin{cases} C_f = 2 \mu F \\ L_f = 1,4 \text{ mH} \end{cases}$$

5. A corrente eficaz  $I_{C_{o_{ef}}}$  é calculada pela Equação (58). Devido ao seu valor, como definido por Fabiana Pottker de Souza *et al.* (2000), associou-se dois capacitores  $C_o$  em paralelo, formando um conjunto de  $8,6 \text{ mF}$ , resultando uma tensão de ondulação na saída na ordem de  $2,76 \text{ V}$ :

$$I_{C_{o_{ef}}} = \frac{\Delta I_o}{2\sqrt{2}} = \frac{17,9}{2\sqrt{2}} = 6,33 \text{ A} \quad (58)$$

### 5.1.1 ESFORÇOS NOS SEMICONDUTORES

Os esforços no semicondutores encontram-se definidos pelos cálculos que seguem, o que está de acordo com o apresentado por Fabiana Pottker de Souza *et al.* (2000).

1. Para encontrar, de modo simplificado, os esforços nos semicondutores exige-se, pelo método apresentado por Fabiana Pottker de Souza *et al.* (2000), o cálculo do sinal modulador de pico, o qual é avaliado pela Equação (59). Neste caso o autor arbitrou o valor de pico do portador em 6 volts.

$$V_{m(pico)} = M \cdot V_{p(pico)} = 0,386 \cdot 6 = 2,32 \text{ V} \quad (59)$$

2. Corrente de pico na chave S:

$$i_{S(pico)} = i_{D_{RL(pico)}} = I_{O(máx)} + \frac{\Delta I_o}{2} = 34 \text{ A} \quad (60)$$

3. Corrente média na chave S para  $R_{SH}$  de 0,1:

$$i_{S(med)} = \frac{V_{m(pico)}}{R_{SH}} \frac{2}{\pi} = \frac{2,32 \cdot 2}{0,1 \cdot \pi} = 14,74 \text{ A} \quad (61)$$

4. Corrente eficaz na chave S:

$$i_{S(ef)} = \frac{V_{m(pico)}}{R_{SH}} \frac{1}{\sqrt{2}} = \frac{2,32}{0,1 \cdot \sqrt{2}} = 16,37 \text{ A} \quad (62)$$

5. Corrente média no diodo roda livre:

$$i_{D_{RL(med)}} = I_{O(máx)} - i_{S(med)} = 25 - 14,74 = 10,26 \text{ A} \quad (63)$$

6. Corrente eficaz no diodo roda livre:

$$i_{D_{RL}(ef)} = \sqrt{I_{O(máx)}^2 + \frac{\Delta I_O^2}{8} - i_{S(ef)}^2} = \sqrt{25^2 + \frac{17,9^2}{8} - 16,37^2} = 19,92 \text{ A} \quad (64)$$

7. Corrente de pico na ponte retificadora:

$$i_{D_{Ret}(pico)} = i_{S(pico)} = 9,65 \text{ A} \quad (65)$$

8. Corrente média na ponte retificadora:

$$i_{D_{Ret}(med)} = \frac{i_{S(pico)}}{\pi} = 3,072 \text{ A} \quad (66)$$

9. Corrente eficaz na ponte retificadora:

$$i_{D_{Ret}(ef)} = \frac{i_{S(pico)}}{2} = 4,83 \text{ A} \quad (67)$$

A ponte retificadora escolhida é a D15XB60:

$$\begin{cases} 15 \text{ A} \\ 600 \text{ V} \end{cases}$$

A chave de comutação escolhida foi o MOSFET STPN40N60:

$$\begin{cases} I_C = 34 \text{ A}, V = 650 \text{ V} \\ R_{DS(on)} = 0,088 \Omega \\ T_j = -55 \text{ to } 150^\circ \text{ C} \\ R_{thjc(máx)} = 0,5^\circ \text{ C/W} \end{cases}$$

Para o circuito do *snubber* o diodo escolhido foi VS-60APU06-N3:

$$\begin{cases} I_F = 60 \text{ A}, 600 \text{ V} \\ V_F = 1,35 \text{ V} \\ R_{thjc} = 0,63 \text{ K/W} \end{cases}$$

### 5.1.2 CONDICIONAMENTO DE SINAIS

Na seção 3.2 discuti o Buck PFC apresentado por F Pottker Souza e Barbi (1999), a partir desta seção serão apresentados os aspectos do *hardware* proposto para o controle digital do retificador. Normalmente o controle digital tem a necessidade de circuitos auxiliares com o objetivo de acomodar os sinais entre as unidades de controle e de potência. Para tanto utiliza-se de circuitos de comando para o acionamentos das chaves de potência e filtros para evitar a sobreposição na leitura dos sinais de entrada do controlador digital.

As aplicações com controle digital normalmente realizam amostragem de grandezas analógicas para digital, sendo o efeito de sobreposição por frequências superiores a metade da frequência de amostragem, conhecidos por *aliasing*, é indesejado. Portanto, para evitar a ocorrência de tal afeito, utiliza-se os filtros anti-aliasing na aquisição dos sinais para a unidade de controle.

Como sugerido por Greff (2009), de acordo com a Equação (68), observa-se a função de transferência para o filtro anti-aliasing, onde  $K$  representa a frequência de corte.

$$G_{FAA}(s) = \frac{K}{s + K} \quad (68)$$

A frequência de corte encontra-se posicionada na metade da frequência de amostragem, a Equação (69) e  $f_a$  é a frequência de amostragem.

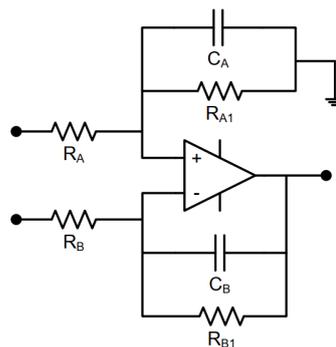
$$K = \pi \cdot f_a \quad (69)$$

Considerando uma frequência de amostragem de  $15 \text{ kHz}$  e arbitrado o valor de  $R_A = R_B = 10 \text{ k}\Omega$ , representados na Equação (70) por  $R$ , obtém-se o valor de  $C_A$  e  $C_B$  para  $3,3 \text{ nF}$ .

$$C_A = C_B = \frac{1}{R \cdot K} = 3,3 \text{ nF} \quad (70)$$

A Figura 48 apresenta o diagrama esquemático do filtro anti-aliasing proposto por Greff (2009).

Figura 48 – Filtro anti-aliasing



Fonte: Adaptado de (GREFF, 2009)

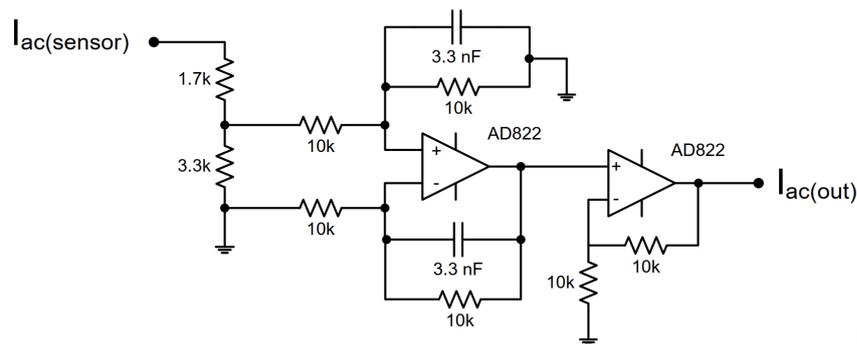
### 5.1.3 CIRCUITOS AUXILIARES

#### 1. Sensores:

- a. Amostragem da Corrente de Entrada: Para a amostragem da corrente de entrada foi utilizado o sensor LES 15-NP com uma corrente nominal de 15 A e um ganho

de 1:2000. Como o microcontrolador utilizado opera com nível de tensão de 3,3 V, foi atribuído um divisor resistivo para adequar os níveis de tensão entre o sensor e o condicionador devido ao *offset*. Outro ponto relevante é fato da adição de um diodo zener de 3,3 V para limitar em amplitude o sinal de saída do condicionador para preservar a entrada do microcontrolador. O diagrama esquemático do condicionador em questão, adaptado de Greff (2009), pode se verificado na Figura 49.

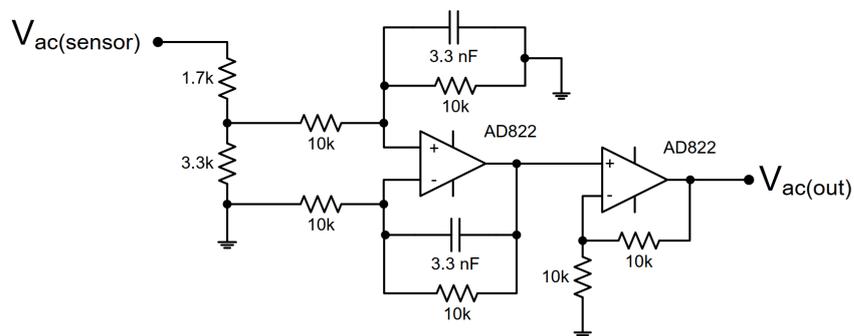
Figura 49 – Amostragem da corrente de entrada



Fonte: Adaptado de (GREFF, 2009)

- b. Amostragem da Tensão de Entrada: No que diz respeito a amostragem e condicionamento da tensão de entrada foi utilizado um módulo ZMPT101B. O tratamento do sinal de saída do módulo de tensão foi o mesmo que para o sensor de corrente visto na seção 1. O condicionador para a tensão de linha pode ser observado no diagrama da Figura 50.

Figura 50 – Amostragem da tensão de entrada

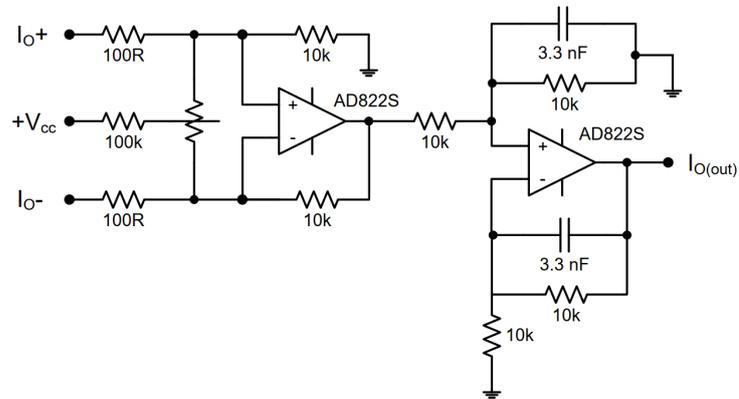


Fonte: Adaptado de (GREFF, 2009)

- c. Amostragem das Correntes de Saída: Para as correntes  $I_o$  e  $I_{L_o}$  optou-se por corrigir o *offset* de modo físico e não no *firmware* do controle digital. O objetivo do tratamento externo ao controle digital dá-se porque a corrente de entrada encontra-se atrasada em relação a corrente de saída, e o retorno da corrente de saída é ponto

crítico da arquitetura de controle apresentada por F Pottker Souza e Barbi (1999). A Figura 51 apresenta apenas o diagrama esquemático para o condicionamento de  $I_o$ , porque o de  $I_{L_o}$  é idêntico.

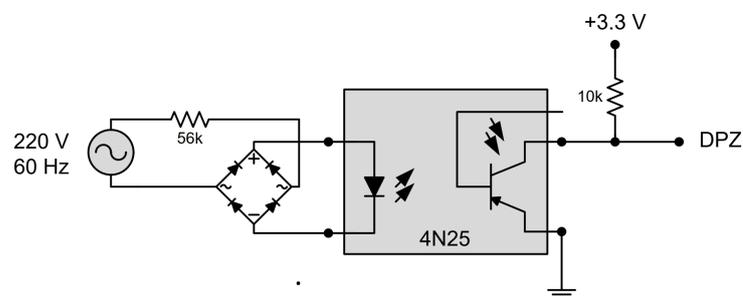
Figura 51 – Amostragem da Corrente de Saída



Fonte: Adaptado de (HOROWITZ *et al.*, 1989; GREFF, 2009)

2. Sincronismo com a Tensão de Linha: Optou-se por sincronizar o sistema de controle digital com a tensão de linha de entrada por meio de um circuito Detector de Passagem por Zero (DPZ). Tal procedimento também poderia ser feito via *software* com a implantação de um PLL (*Phase Lock Loop*). Como o algoritmo de controle possui uma demanda muito intensa de processamento devido a rede neural, avaliou-se que a concorrência pelo processador entre o PLL e o ANNC deveria ser contornada, o que justifica o uso do DPZ. O detector de passagem por zero tem como base o dispositivo 4N25 e o diagrama esquemático encontra-se na Figura 52.

Figura 52 – Detector de passagem por zero



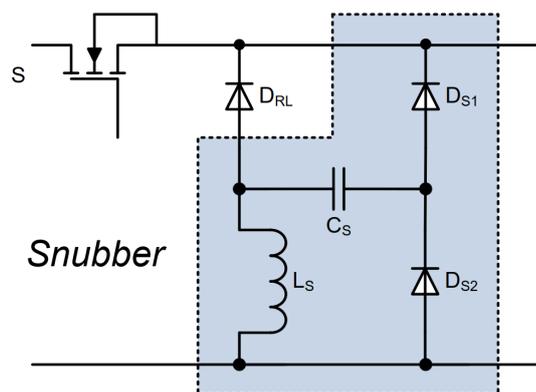
Fonte: Autoria própria.

3. Circuito de Comando: Originalmente o comando utilizado para o Buck PFC apresentado por F Pottker Souza e Barbi (1999) foi o IR2111, contudo neste estudo foi utilizado o IR2104 sem prejuízo para o projeto. Os níveis lógicos do sinal dos moduladores PWM

do microcontrolador STM32F446R assumem os valores 0 e 3.3 V, o que está de acordo com o *datasheet* do IR2104, pois este reconhece tais níveis lógicos diretamente, não havendo a necessidade do uso de *buffers*.

4. *Snubber*: O acionamento da chave  $S$  representa um ponto crítico do circuito de potência do ANNC, uma vez que a corrente sobre a chave, considerada constante, é comutada a uma frequência alta na ordem de  $30\text{ kHz}$ . Com o objetivo de minimizar o efeito da recuperação reversa do diodo  $D_{RL}$ , Fabiana Pottker de Souza *et al.* (2000) adotou o *snubber* passivo não-dissipativo desenvolvido por Tardiff e Barton (1989), o qual encontra-se diagramado na Figura 53, e seus componentes são:  $D_{S1}$ ,  $D_{S2}$ ,  $C_S$  e  $L_S$ . De acordo com F Pottker Souza e Barbi (1999) os valores adotados para  $L_S$  e  $C_S$ , nessa ordem, são  $3.4\ \mu\text{H}$  ( $EE\ 30/7, 5\text{ espiras}, 13\text{ fios } 19\text{ AWG}$ ) e  $100\text{ nF}$ .

Figura 53 – Diagrama esquemático *snubber* não-dissipativo



Fonte: Adaptado de (SOUZA, F. P. d. *et al.*, 2000)

#### 5.1.4 PROCESSAMENTO DIGITAL

O processamento dos sinais devidamente condicionados ficou a cargo do módulo NUCLEO-L491RG da STM, que ocupa o papel principal do sistema de controle do ANNC. O microcontrolador desse módulo é o STM32L491RG e sua CPU (*Central Processing Unit*) ARM pode operar a uma frequência de 170 MHz, também possui dois DMAs (*Direct Memory Access*) o que permite contornar a CPU ao utilizar o ADC (*Analogue-to-Digital Converter*) bem como o PWM, e assim otimizar o processo de tratamento dos sinais. Outro ponto importante é a FPU (*Float Point Unit*), com a qual é possível acelerar o processamento numérico com ponto flutuante, o que customiza a computação da rede neural do ANNC. A Figura 54 apresenta o *hardware* da placa de desenvolvimento NUCLEO-L491RG.

Figura 54 – Kit de desenvolvimento NUCLEO-L491RG



Fonte: Adaptado de (STMICROELECTRONICS, s.d.)

## 5.2 PARÂMETROS DO SISTEMA PARA AS SIMULAÇÕES

Os resultados obtidos a partir das simulações, realizadas pelo software PSIM, serão apresentados com o objetivo de comprovar o método proposto para o controle do retificador Buck PFC, onde este encontra-se ilustrado na Figura 55.

O ambiente de simulação foi configurado com passo de tempo igual a  $1 \mu s$  e tempo total de  $1000 ms$ . O recurso para o desenvolvimento da rede neural no PSIM foi o "C Block", que utiliza a linguagem de programação C. No que tange aos parâmetros do ANNC, estão disponíveis na Tabela 4 com destaque para  $\beta_{(bias)}$ , haja visto que a atualização do peso relativo ao *bias* ocorre independente dos demais por meio do algoritmo RMSProp.

Tabela 4 – Parâmetros de simulação para as RNAs.

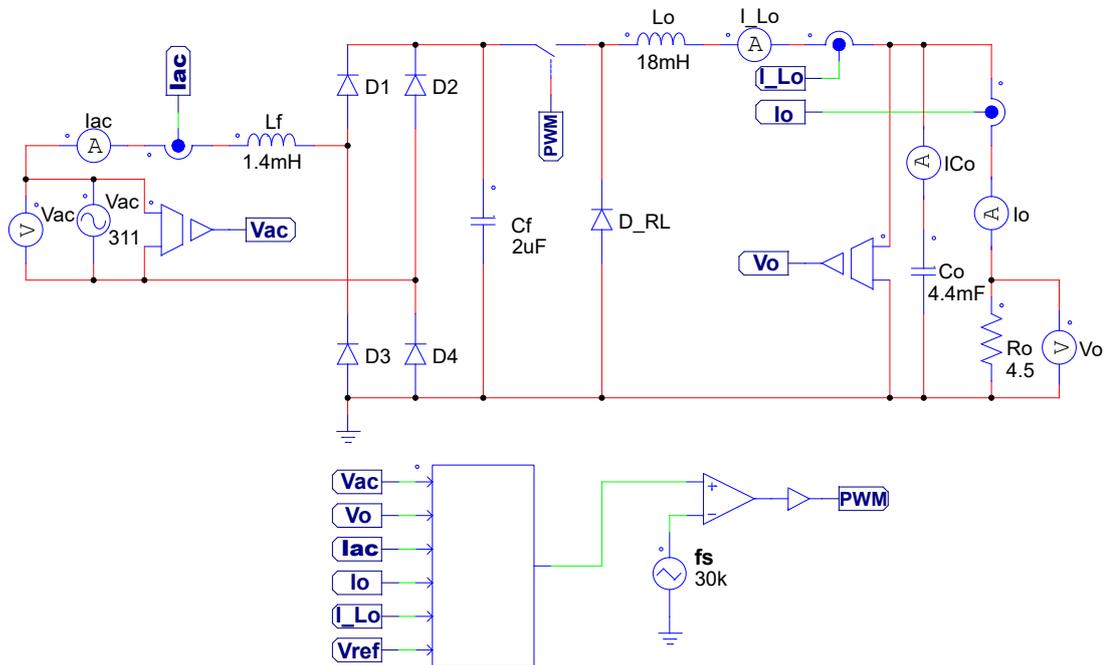
$E[\delta^2]$	$E[\delta^2]_{(n-1)}$	$\beta$	$\beta_{(bias)}$	$\epsilon$	$\eta_{(inicial)}$	<i>threshold</i>	$\alpha$	<i>pesos iniciais</i>
1.0e-3	1.0e-3	0.9	0.999	1.0e-8	1.0e-3	1.0e-3	1.0	0.0

Fonte: Autoria própria.

## 5.3 RESULTADOS DAS SIMULAÇÕES

Haja visto que as simulações, no que diz respeito aos parâmetros do Buck, das arquiteturas das RNAs aplicadas ao ANNC, obtiveram resultados numéricos muito próximos, então

Figura 55 – Diagrama do Buck PFC proposto.



Fonte: Autoria própria - Simulador PSIM.

optou-se por ilustrar os gráficos da arquitetura MLP no Apêndice B, e os resultados que dizem a respeito a arquitetura Monocamada segue no decorrer deste capítulo.

Portanto, nesta seção são apresentadas as respostas obtidas pelo ANNC atuando sob o modo instantâneo a partir de uma RNA Perceptron, onde a atualização dos parâmetros da rede neural ocorre em tempo real. Com isto o algoritmo opera no contexto do treinamento (*loop* constante entre os modos *forward* e *backward*), e assim na medida que este evolui atualiza-se a saída da rede, a qual representa a razão cíclica que é base para a obtenção da modulação senoidal do PWM.

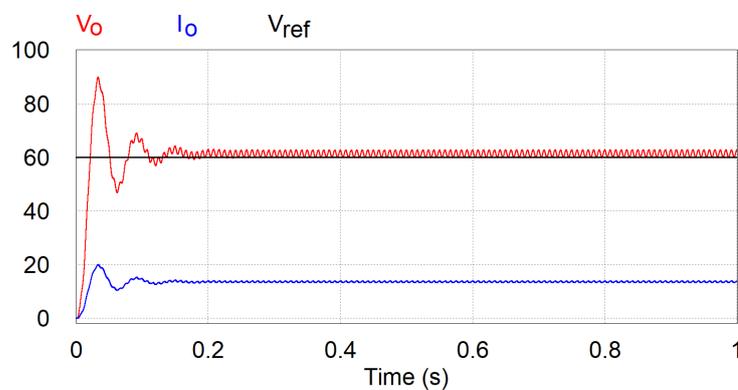
### 5.3.1 OPERAÇÃO SEM AS TÉCNICAS *FEEDFORWARD CURRENT* E NEURÔNIO ADITIVO

No trabalho desenvolvido por Silva *et al.* (2021) é contextualizado um controlador baseado em rede neural aplicado ao conversor CC-CC Buck, porém não se observa a característica temporal dada pelo neurônio aditivo.

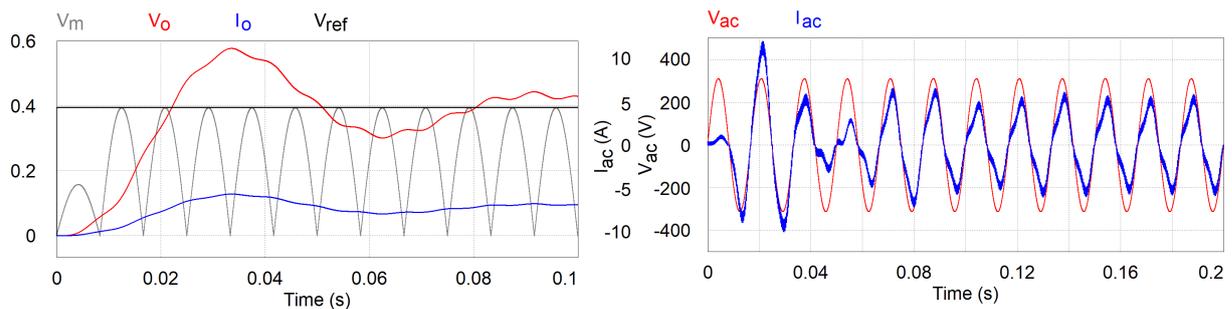
O ANNC sem a adição do neurônio aditivo e a técnica *Feedforward Current*, opera de modo semelhante ao evidenciado por Silva *et al.* (2021), porém não corrige a distorção da corrente de entrada, nem tão pouco apresenta resposta em tempo real para distúrbios de corrente ocorridos na saída. Nos gráficos apresentados na Figura 56 é ilustrada a resposta do ANNC para o cenário onde a técnica *Feedforward Current* e o neurônio aditivo não estão presentes.

Observa-se pela Figura 56(b) que  $V_m$  é ajustada apenas em sua amplitude, esse aspecto ocorre em todo o intervalo analisado, porém neste cenário optou-se por destacar apenas o momento transitório. Para o mesmo intervalo, da 0 a 100 ms, na Figura 56(c), a corrente  $I_{ac}$  aumenta significativamente, e após o tempo de transitório a amplitude é normalizada porém a forma fica distorcida, corroborando para alteração no FP. No que diz respeito a tensão de saída, após o período de transitório, o ajuste de  $V_o$  ocorre de acordo com  $V_{ref}$ , o que pode ser conferido na Figura 56(a).

Figura 56 – Resposta do ANNC sem as características do neurônio aditivo e da técnica *feed-forward current*. ANNC encontra-se configurado com função de ativação ELU e taxa de aprendizado individualizada para o *bias* definida pelo algoritmo RMSProp. Intervalo de análise de 0 a 1000 ms. Potência de saída de 800 W.  $V_o$ ,  $I_o$  e  $V_{ref}$  da Figura 56(b) encontram-se normalizados no intervalo [0 1].



(a) De 0 a 200 ms o sistema encontra-se sujeito ao período de transitório, onde observa-se momentos de sobretensão e sobrecorrente para  $V_o$  e  $I_o$ .



(b) Período de transitório de 0 a 100 ms ampliado, onde observa-se que  $V_m$  não é corrigida na amplitude e na forma. (c) Período de transitório de 0 a 200 ms ampliado, onde observa-se que  $I_{ac}$  apresenta distorções na forma e na amplitude devido a falta de ajuste em  $V_m$ .

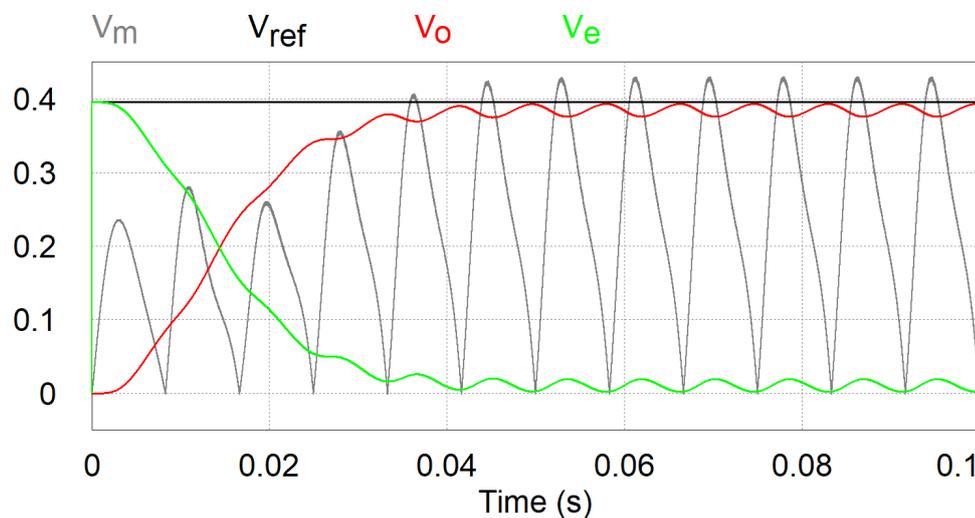
Fonte: Autoria própria - Simulador PSIM.

Os pontos abordados no cenário em questão, ainda que promissores, não tratam de um resultado esperado para o ANNC, o que fortalece a utilização das redes neurais com característica de neurônio aditivo somada a técnica *Feedforward Current* como base para o ANNC, onde a título de exemplo tem-se o Buck PFC, o qual terá seus resultados expressos na Seção 5.3.2.

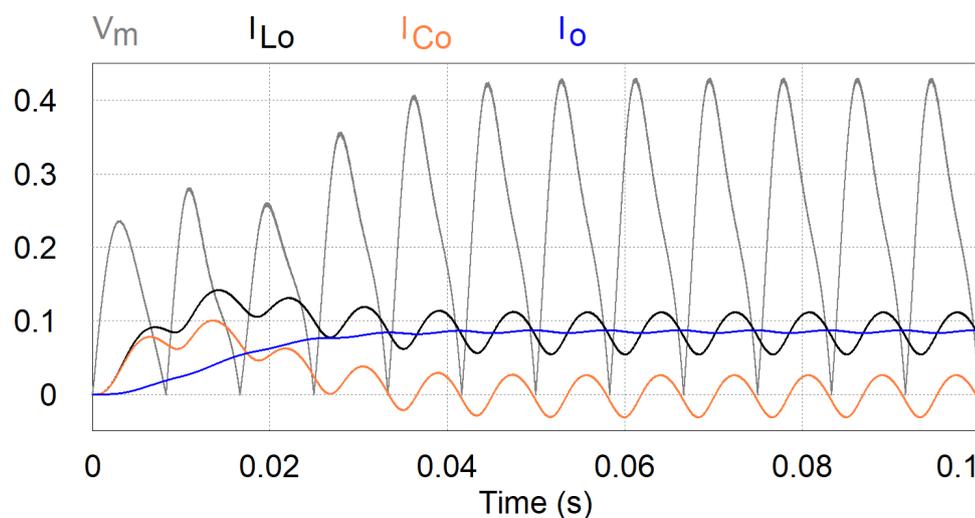
### 5.3.2 OPERAÇÃO COM AS TÉCNICAS *FEEDFORWARD CURRENT* E NEURÔNIO ADITIVO

Observa-se pela Figura 57(a), que a partir do momento que o ANNC inicia a atuação sobre o controle do Buck, o erro entre  $V_{ref}$  e  $V_o$ , identificado como  $V_e$ , é minimizado de modo que  $V_o$  se aproxima de  $V_{ref}$ . Na Figura 57(b) fica evidente a resposta do ANNC no controle de  $V_o$  e  $I_o$  ainda que se observa uma alteração acentuada, entre 0 e 0.02s, em  $I_{L_o}$  devido a  $I_{C_o}$ . Outro ponto de destaque é a variação na amplitude de  $V_m$ , a qual ocorre no sentido de corrigir tanto  $V_o$  quanto  $I_o$  de perturbações nos parâmetros do Buck.

Figura 57 – ANNC no controle de  $V_o$  e  $I_o$  a partir do ajuste na variação de  $V_m$ . Resposta para uma carga de 800 W com indutor de saída de 18 mH.  $V_{ref}$ ,  $V_o$  e  $V_e$  encontram-se normalizados no intervalo [0 1].



(a) ANNC Monocamada no controle de  $V_o$ .



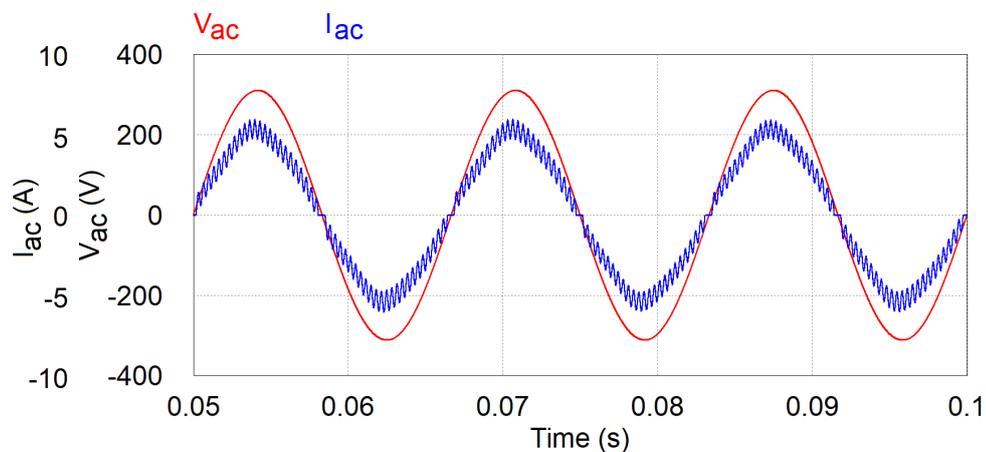
(b) ANNC Monocamada no controle de  $I_o$ .

Fonte: Autoria própria - Simulador PSIM.

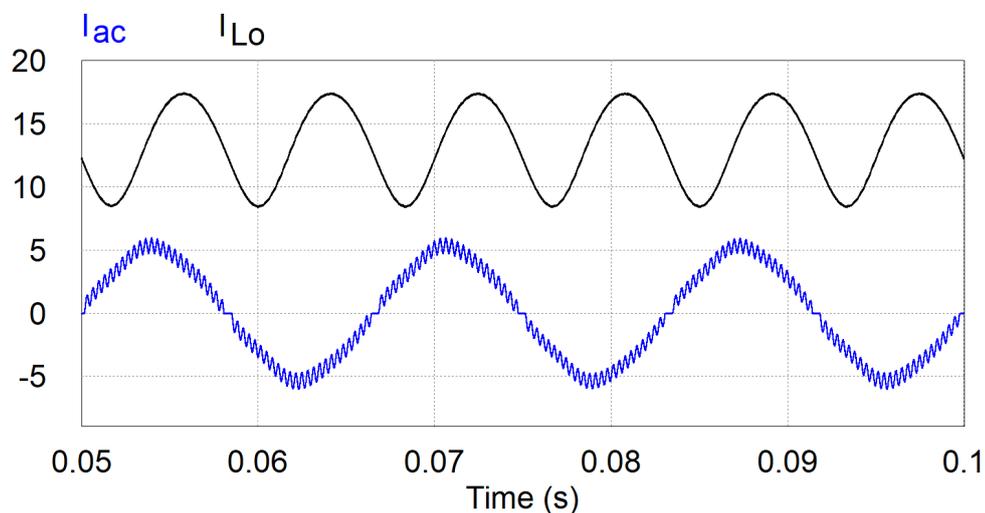
Os gráficos identificados na Figura 58, constam da tensão e da corrente de entrada,

$V_{ac}$  e  $I_{ac}$ , e também da corrente de saída,  $I_{L_o}$ . Ao observar o formato do sinal de  $I_{ac}$  não se percebe deformação na corrente, ainda que o conversor tenha sido configurado para trabalhar próximo do seu limite inferior de operação. Em tal cenário, o FP encontrado foi de 0.99277, muito próximo da unidade, como aventado inicialmente por F Pottker Souza e Barbi (1999). Observa-se que o conversor opera dentro do limite definido para as correntes  $I_{ac}$  e  $I_{L_o}$ , de sorte que  $I_{L_o}$  mantém-se sempre superior ao valor absoluto de  $I_{ac}$ , o que necessário para evitar distorção na corrente de entrada.

Figura 58 – Gráfico da tensão e da corrente de entrada,  $V_{ac}$  e  $I_{ac}$  para um FP = 0,99277. Resposta para uma carga de 800 W com indutor de saída de 18 mH.



(a) ANNC Monocamada no controle de  $I_{ac}$ .



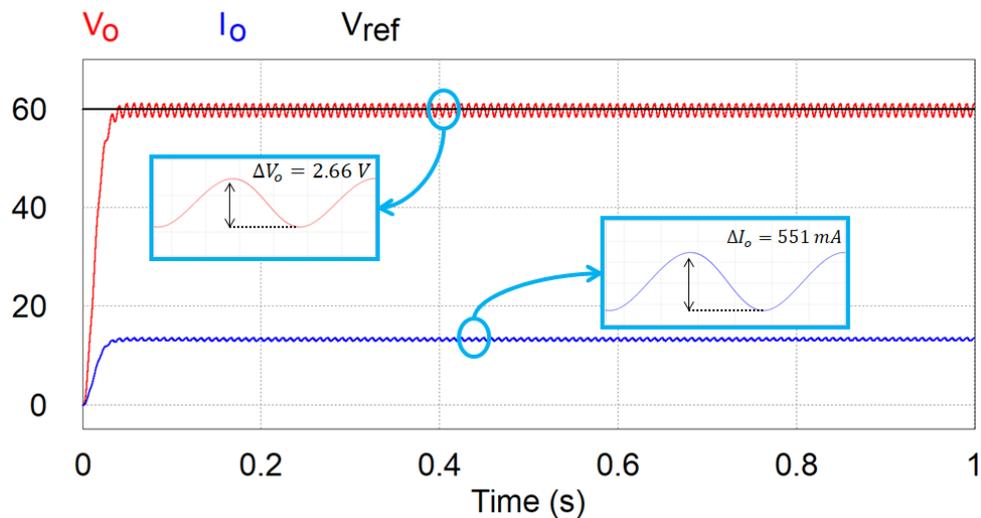
(b) ANNC Monocamada no controle de  $I_{L_o}$ .

Fonte: A autoria própria - Simulador PSIM.

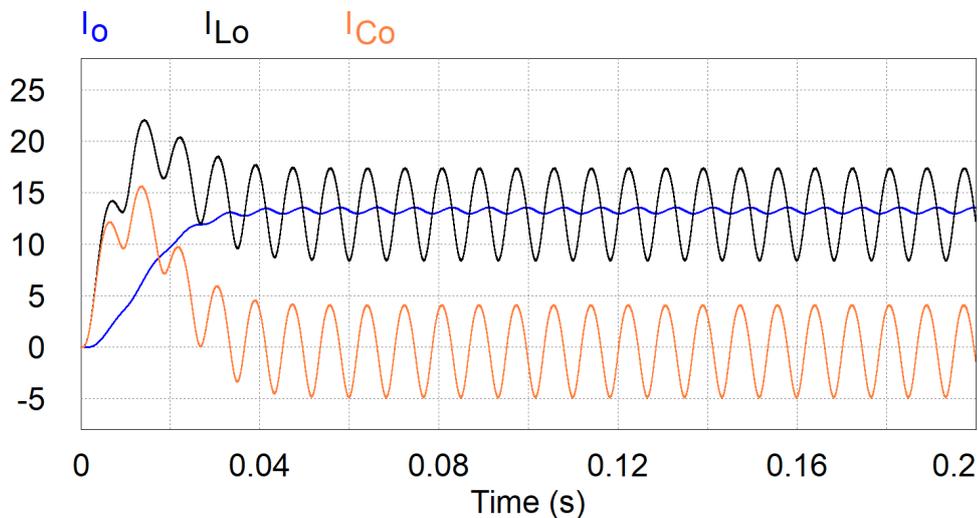
Considerando a Figura 59, a qual relaciona as grandezas  $V_o$ ,  $I_o$  e  $V_{ref}$ . A tensão de referência,  $V_{ref}$ , encontra-se configurada para 60V, como consta na Tabela 3, portanto, espera-se que o valor médio de  $V_o$  assumira esse potencial, e é justamente o que se observa,  $V_o \approx 59,58$  V. A corrente de saída atinge o valor  $I_o \approx 13,41$  A, como aguardado, haja visto que  $R_o = 4,5$   $\Omega$ . Em ambos os casos o erro ficou abaixo de 0,01 %, onde  $\Delta V_o$  e  $\Delta I_o$

permaneceram dentro dos limites de operação do conversor.

Figura 59 – Gráficos da tensão e da corrente de saída,  $V_o$  e  $I_o$ , para o ANNC com RNA Monocamada. Resposta para uma carga de 800 W com indutor de saída de 18 mH.



(a) Análise de  $V_o$ ,  $I_o$  e  $V_{ref}$  para o intervalo de 0 a 1 s .



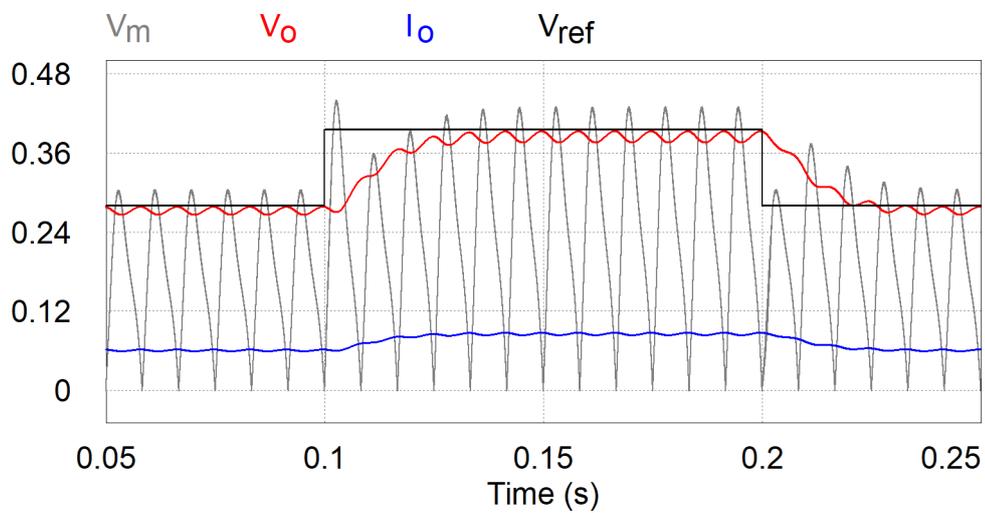
(b) Análise de  $I_o$ ,  $I_{Lo}$  e  $I_{Co}$  para o intervalo de 0 a 200 ms .

Fonte: Autoria própria - Simulador PSIM.

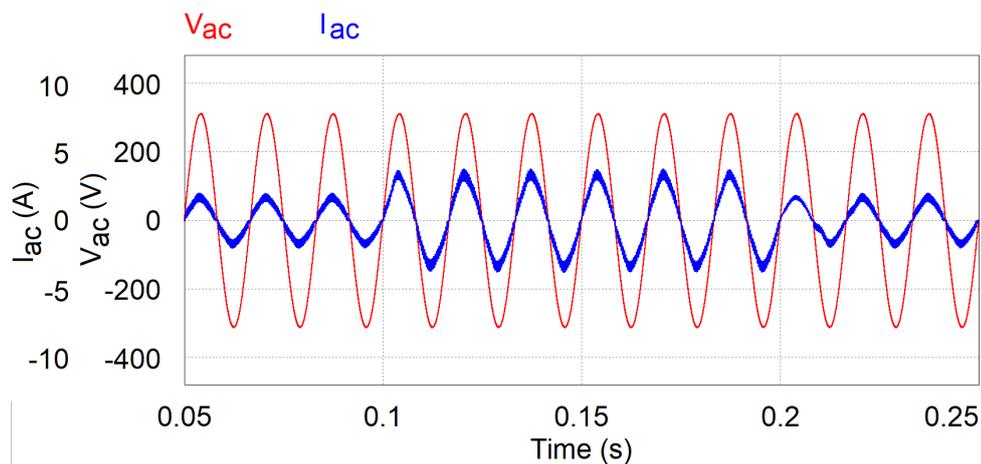
O cenário ilustrado na Figura 60 tem como objetivo demonstrar a atuação do ANNC frente a dois degraus em  $V_{ref}$  sem fugir dos limites de operação determinados para o Buck PFC. Para atender aos requisitos de operação,  $R_o$  assume  $2,4 \Omega$ , com isso  $V_{ref}$  poderá adotar os valores:  $42,5V$  e  $60V$ . Diante do exposto nos gráficos evidencia-se nas transições de  $V_{ref}$  que a amplitude de  $V_m$  é ajustada sem alterar a forma de onda do sinal, dessa maneira é possível controlar  $V_o$  e manter  $I_{ac}$  sem distorção.

O ANNC mostrou-se extremamente robusto ao corrigir  $V_o$  na medida que identificou variações em  $V_{ref}$ , como exemplificado na Figura 60. De igual sorte, no tocante a Figura 61, o

Figura 60 – Resposta do ANNC ao degrau em  $V_{ref}$ , com indutor de saída de 18 mH.  $V_o$ ,  $I_o$  e  $V_{ref}$  encontram-se normalizados no intervalo [0 1].



(a) Correção de  $V_m$  ao degrau em  $V_{ref}$ .

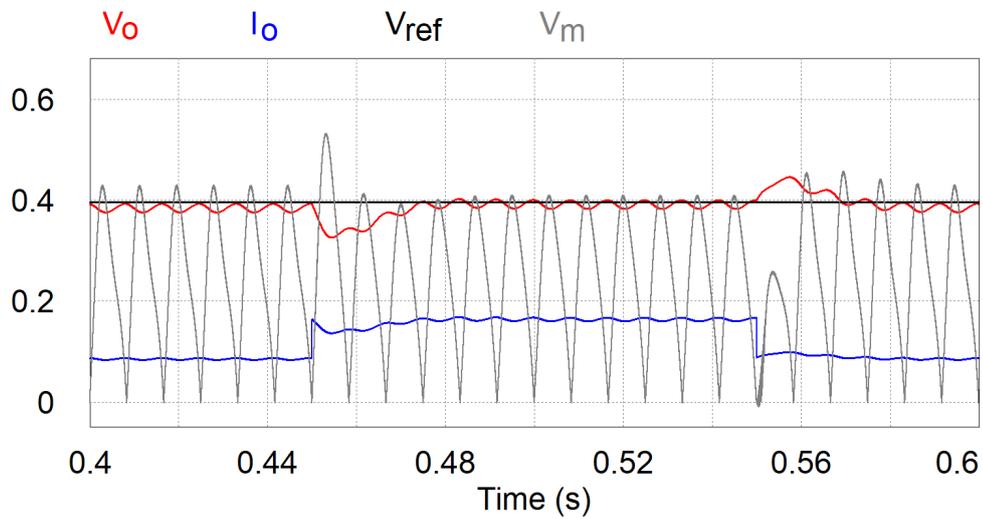


(b) Reflexo da correção de  $V_m$  em  $V_{ac}$  e  $I_{ac}$  para manter o PFC próximo de 100 %.

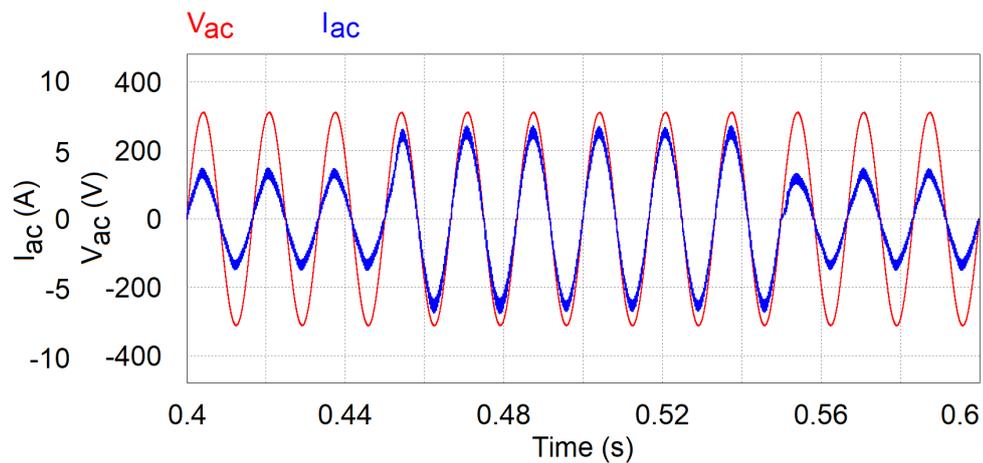
Fonte: Autoria própria - Simulador PSIM.

controlador encontra-se exposto a alteração no valor de  $R_o$ , de modo que o Buck fique sujeito a dois degraus em  $P_o$ , um no tempo de 0.45 s e outro no tempo de 0.65 s. No tempo de 0.45 s  $R_o$  diminui instantaneamente de 4,5  $\Omega$  para 2,4  $\Omega$  o que promove um salto em  $P_o$  de 800 W para próximo de 1500 W. Já no tempo igual a 0.65 s o valor de  $R_o$  cresce subitamente de 2,4  $\Omega$  para 4,5  $\Omega$  o que promove uma queda brusca em  $P_o$  de 1500 W para 800 W, ainda assim o ANNC consegue corrigir  $V_o$  de acordo com  $V_{ref}$ . Destaca-se que nos instantes em que  $P_o$  altera-se repentinamente,  $I_{ac}$  é corrigida no tempo correspondente a meio ciclo do período da rede, ou seja, em aproximadamente 8.33 ms, sendo assim pode-se afirmar que o FP médio mantém-se próximo da unidade.

Figura 61 – Atualização de  $V_m$  frente a variação em  $P_o$  alternando entre 800 e 1500 watts com indutor de saída de 18 mH.  $V_o$ ,  $I_o$  e  $V_{ref}$  encontram-se normalizados no intervalo [0 1].



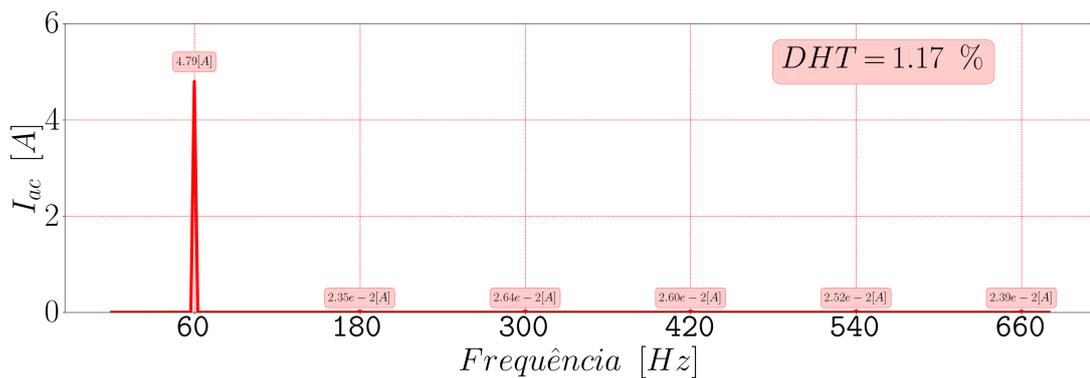
(a) RNA Monocamada .



(b) RNA Monocamada .

Fonte: Autoria própria - Simulador PSIM.

Figura 62 – Espectro harmônico da corrente de entrada. Resposta para uma carga de 800 W com indutor de saída de 18 mH.



Fonte: Autoria própria - Simulador PSIM.

As características harmônicas de  $I_{ac}$  ilustradas nos gráficos dispostos na Figura 62, demonstram que o controle neural apresenta-se eficiente diante das constantes variações dos estímulos de entrada do sistema. O valor calculado da DHT, levando em conta apenas as componentes harmônicas da 3<sup>a</sup> a 11<sup>a</sup> ordem, é de apenas 1,17 %.

#### 5.4 CONCLUSÃO

A utilização de redes neurais no contexto da eletrônica de potência não é recente, fato averiguado no desenvolvimento deste estudo. De posse dessa premissa o ANNC foi desenvolvido no sentido, dentre outros aspectos, de representar uma contrapartida aos métodos tradicionais de controle para retificadores Buck. De acordo com os resultados apresentados pelas simulações, pode-se afirmar que o ANNC atendeu as especificações desejadas para um retificador Buck PFC e, portanto, pode ser considerado como alternativa frente aos controladores clássicos.

No âmbito deste capítulo, considerou-se apenas os aspectos de projeto do Buck PFC, a definição física de seus indutores foi destinada ao Apêndice D.

## 6 RESULTADOS EXPERIMENTAIS

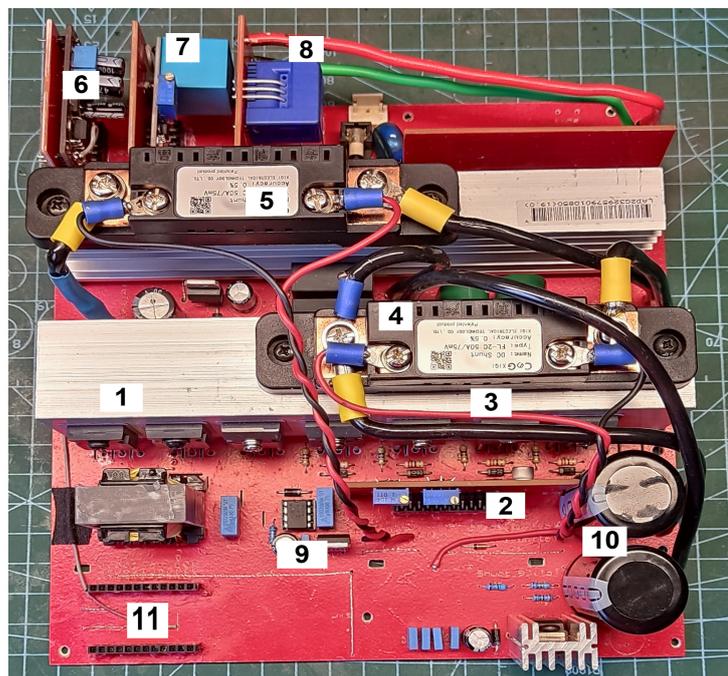
Este capítulo se detém a expor os resultados experimentais e confrontá-los com os obtidos a partir das simulações no que diz respeito a rede Monocamada, haja visto que esta apresentou desempenho satisfatório no decorrer das simulações numéricas frente ao controle do Buck PFC, bem como se comparada com a arquitetura MLP, o que possibilita minimizar a exigência de *hardware* com maior poder de processamento para o protótipo. Também apresenta o protótipo que deu origem aos resultados ilustrados no capítulo em questão.

### 6.1 PROTÓTIPO

O protótipo para o sistema de potência, os módulos para o condicionamento dos sinais e a unidade de carga podem ser observados nas Figuras 63, 64 e 66, e os indutores dos filtros de entrada ( $L_f$ ) e saída ( $L_o$ ) podem ser acompanhados na Figura 65. O protótipo foi arquitetado de modo que pudessem ser utilizadas até 4 chaves de comutação. Os módulos para o condicionamento dos sinais foram desenvolvidos no formato de cartões com o objetivo de minimizar a dimensão do protótipo. Nas Figuras 64(a) e 64(b) encontram-se as imagens do protótipo com perspectiva frontal e traseira. No tocante da Figura 66 foram utilizadas 5 unidades durante os experimentos com o protótipo.

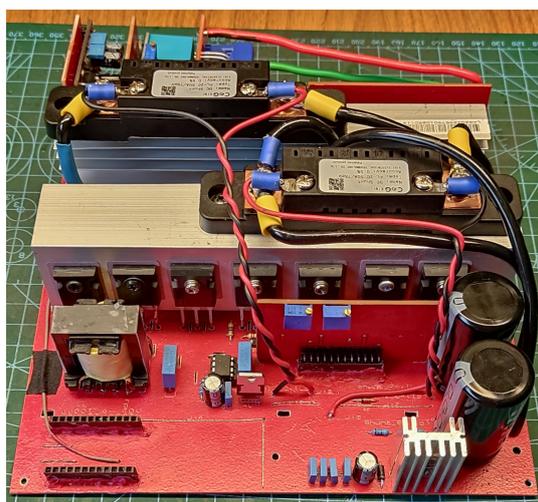
- 1 Componentes do circuito *snubber*,  $L_S$ ,  $C_S$ ,  $D_{S1}$ ,  $D_{S2}$  e também o diodo de roda livre,  $D_{RL}$ .
- 2 O módulo para o condicionamento dos sinais CC,  $I_{L_o}$ ,  $I_o$  e  $V_o$ .
- 3 Chaves de potência.
- 4 Sensor de corrente do *shunt* (50 A, 75 mV, *acurácia* : 0.5), é o sensor para  $I_o$ .
- 5 Sensor de corrente para  $I_{L_o}$ , possui as mesmas características do sensor do item 4.
- 6 Módulo para o condicionamento do sinal do DPZ.
- 7 Módulo para o condicionamento do sinal da tensão de linha de entrada,  $V_{ac}$ .
- 8 Módulo para o condicionamento do sinal da corrente de entrada,  $I_{ac}$
- 9 Comando das chaves de potência, IR2104.
- 10 Capacitor  $C_o$ .
- 11 Conectores para a conexão do sistema de controle.

Figura 63 – Vista superior do protótipo

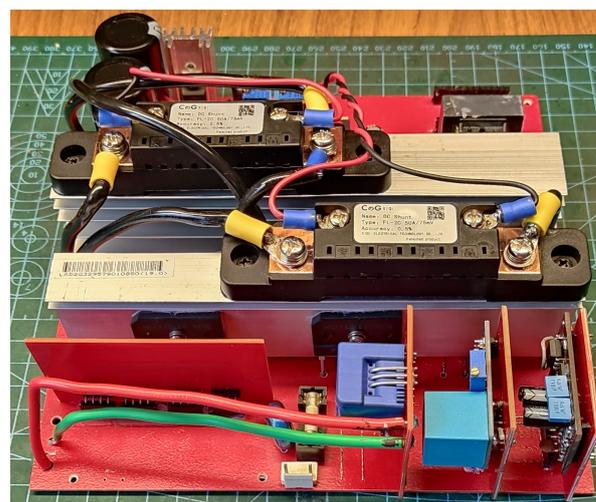


Fonte: Autoria própria.

Figura 64 – Vistas frontal e traseira do sistema de potência e dos módulos para o condicionamento dos sinais do protótipo.



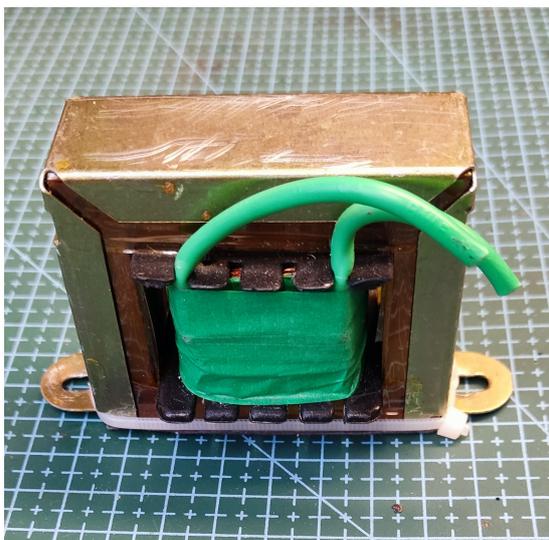
(a) Perspectiva frontal do protótipo.



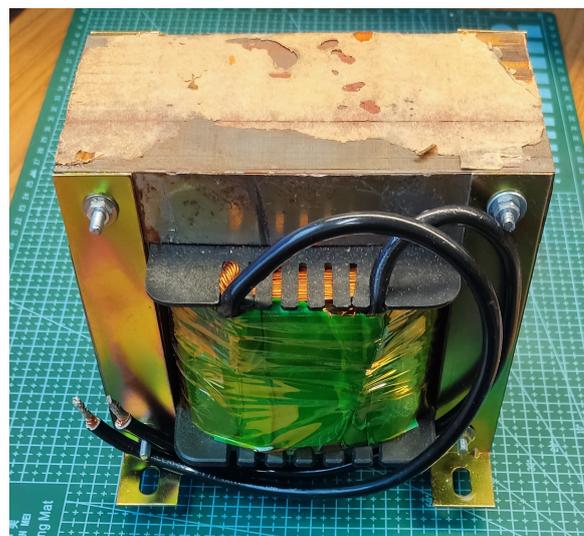
(b) Perspectiva traseira do protótipo.

Fonte: Autoria própria.

Figura 65 – Vistas de  $L_f$  e  $L_o$ .



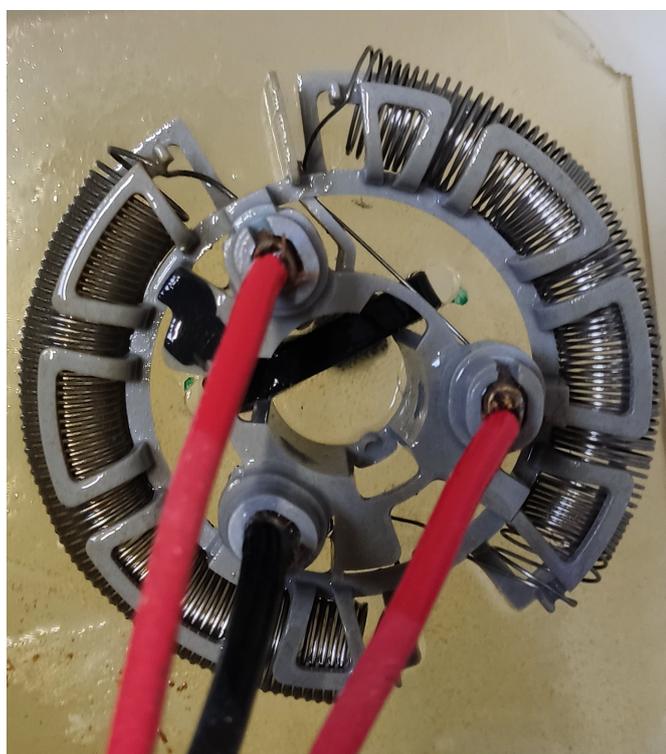
(a) Filtro indutivo de entrada,  $L_f$ .



(b) Filtro indutivo de saída,  $L_o$ .

Fonte: Autoria própria.

Figura 66 – Vista superior da resistência de carga. Potência máxima de 6800W em 220V.



Fonte: Autoria própria.

## 6.2 PARAMETRIZAÇÃO

Segue os pontos de maior relevância definidos para a projeto do ANNC:

### 1. Instrumentação:

Os instrumentos de medida utilizados nos experimentos tratam de um osciloscópio Rigol DS1104Z Plus, duas sondas de corrente UT-P40 da UNI-T e uma sonda de tensão diferencial isolada DP10013 da Micsig.

### 2. Chave de comando:

Foram utilizadas 4 chaves em paralelo com o objetivo de manter  $v_{DS}$  abaixo 1 V durante a comutação, bem como atender aos requisitos de corrente do projeto original proposto por (SOUZA, F. P.; BARBI, 1999). Optou-se por utilizar MOSFET em detrimento do IGBT devido as limitações da frequência de chaveamento oriundas dos IGBTs padrão, na ordem de 10 kHz a 20 kHz, haja visto que os dispositivos do tipo *Silicon Carbid* que operam com frequências maiores não encontravam-se disponíveis no momento.

### 3. Amostragem e sincronismo:

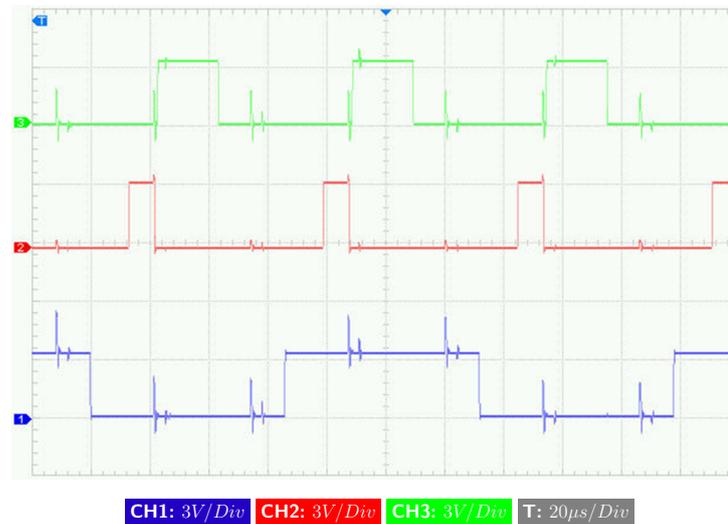
Como na simulação numérica a frequência de chaveamento é de 30 kHz, o controle efetuado, de modo geral, pela técnica *Feedforward Current*, trata da modulação do sinal da rede elétrica a partir do PWM. Sendo assim, para atender aos requisitos de Nyquist (WALDEN, 1999), um sinal modulador com frequência de amostragem de pelo 1200 Hz seria suficiente. No entanto, a frequência de amostragem foi configurada para 15 kHz permitindo que o *duty cycle* seja atualizado a cada 2 ciclos do PWM de controle, a cada  $66 \mu s$ .

A Figura 67 apresenta o encadeamento entre as etapas de operação do ANNC. O **CH1** representa um pulso com duração de  $66 \mu s$ , tanto para o intervalo negativo quanto para o positivo, utilizado para definir o período de processamento do controlador. O intervalo entre a transição do pulso visto no **CH1** e o início do pulso positivo do **CH2**, é de  $12.4 \mu s$  e representa o tempo de processamento do ADC, o qual ocorre via DMA (sem a utilização da CPU). O pulso positivo observado no **CH2** com duração de  $9.4 \mu s$ , representa o período de tratamento do ADC e das rotinas auxiliares. O pulso positivo observado no **CH3**, de  $21.4 \mu s$  de duração, representa o tempo médio de processamento do ANNC. Haja visto que o ADC ocorre via DMA, o período disponível para o processamento do ANNC é de aproximadamente de  $57.2 \mu s$ , representado pelo intervalo entre as transições descendentes em **CH2**.

### 4. Spikes devido a corrente de comutação da chave de comando:

*Spikes* devido a corrente de chaveamento influenciam diretamente na coleta dos sinais de controle. Essa característica precisa ser contornada para manter a leitura do ADC com

Figura 67 – Amostragem e sincronismo. **CH1**: Pulso de sincronismo com  $66 \mu s$ , **CH2**: Processamento ADC com intervalo de  $12.4 \mu s$  e **CH3**: Intervalo de processamento do ANNC.



Fonte: Autoria própria.

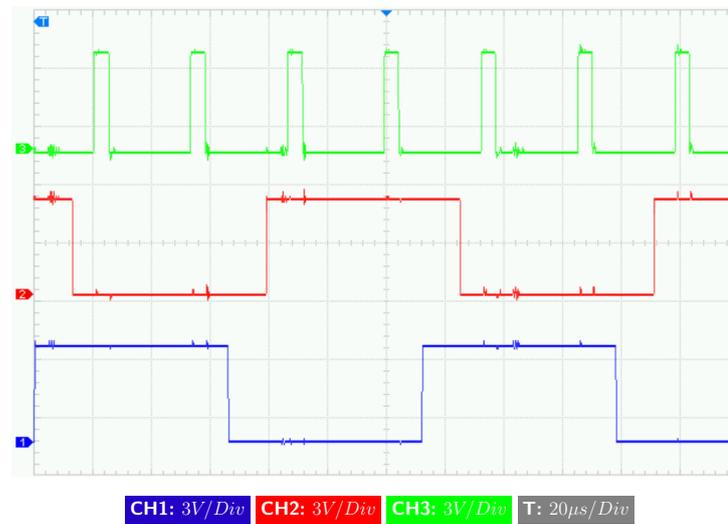
valores consistentes. A solução apontada deve-se a leitura do ADC apenas durante o pulso negativo do PWM. A partir da Figura 68 é possível identificar o sincronismo entre o ADC e o PWM. O **CH1** representa o pulso de sincronismo com duração de  $66 \mu s$ , que determina a taxa de amostragem do ADC. O **CH2** representa a taxa de amostragem do ADC com intervalo de  $66 \mu s$ . O intervalo entre as transições dos pulsos observados em **CH1** e **CH2** é de  $12.4 \mu s$ , que representa o período de conversão do ADC. O sinal observado no **CH3** possui período de  $33 \mu s$  e representa o PWM. Nota-se que o ADC está em operação apenas durante o pulso negativo do PWM, entre as transições dos pulsos presentes no **CH1** e **CH2**, com isso evita-se interferência no ADC devido aos disparos da chave de comando.

### 6.3 RESULTADOS

Espera-se de um sistema de controle em resposta ao degrau inicialização que este entre em regime permanente com *overshoot* mínimo, para tal os tempos de subida, de pico e assentamento devem ser controlados. De acordo com o que se observa na Figura 69, o sistema entrou em regime permanente em pelo menos  $780 ms$  após a inicialização, mostrando a eficiência do método de controle. O objetivo do experimento é evidenciar que o ANNC consegue manter  $V_o$  estável, com  $V_o$  em  $36,20 V$  e  $I_o$  em  $14,5 A$ . Observa-se  $V_o$  sem *overshoot* significativo, o que é mostrado no pico da rampa de inicialização do conversor.

Os gráficos apontados no cenário observado na Figura 70 demonstram o conversor operando dentro da faixa de correção do FP determinada pela técnica *Feedforward Current*,

Figura 68 – Sincronismo do ADC com o PWM. **CH1**: Pulso de sincronismo com  $66 \mu s$ , **CH2**: Amostragem do ADC a cada  $66 \mu s$  e **CH3**: Período do PWM em  $33 \mu s$ .



Fonte: Autoria própria.

Figura 69 – Gráfico da tensão e da corrente de saída,  $V_o$  e  $I_o$ , como resposta do ANNC frente a inicialização para uma carga de 525 W. Para melhor visualização da magnitude dos dados,  $V_o$  encontra-se deslocada por um *offset* de  $-20 V$  e  $I_o$  em  $-20 A$ . **CH3**:  $I_o$  e **CH4**:  $V_o$ .

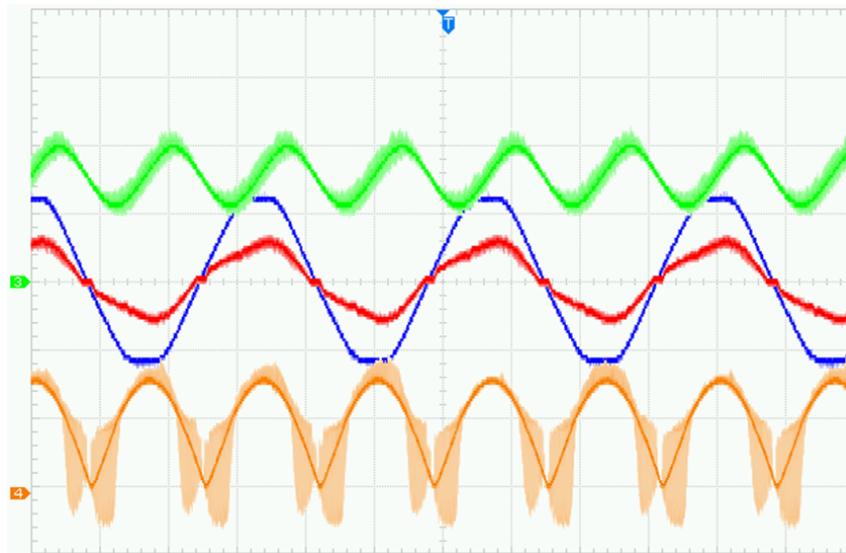


Fonte: Autoria própria.

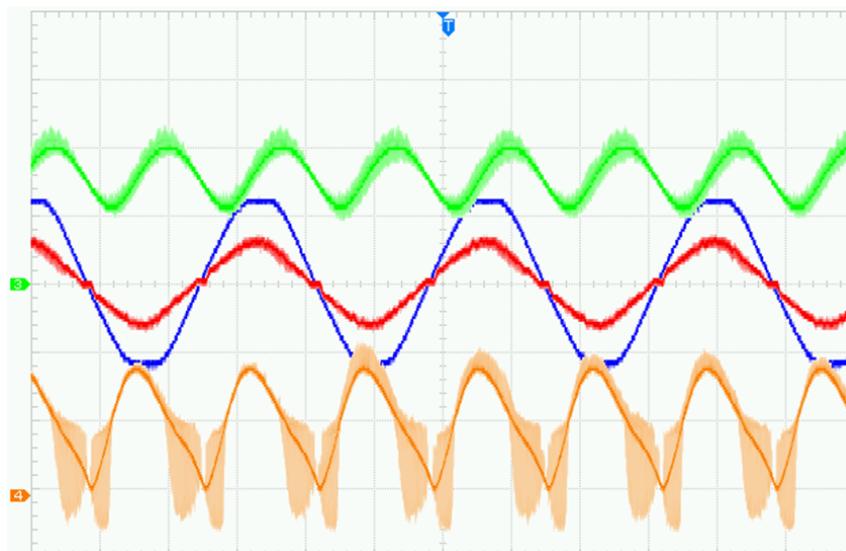
tanto para a não aplicação da técnica, Figura 70(a), quanto para a aplicação da técnica, Figura 70(b). No cenário em questão,  $I_{L_o}$  encontra-se acima do valor absoluto de  $I_{ac}$ , como determina a técnica *Feedforward Current*. A Figura 70(a) apresenta apenas a modulação senoidal, observa-se que  $I_{ac}$  não é corrigida completamente, o que a priori impacta negativamente no fator de

potência. Em contrapartida, o cenário visto na Figura 70(b), sujeito a mesma potência, tem-se a técnica *Feedforward Current* aplicada, percebe-se que  $I_{ac}$  é corrigida. Fica evidente a atuação da técnica *Feedforward Current* e do neurônio aditivo no ajuste da modulação senoidal, o que está de acordo com o que se observa na Figura 26.

Figura 70 – Conversor Buck PFC operando tal qual preconiza a técnica *Feedforward Current*,  $I_{L_o}$  acima do valor absoluto de  $I_{ac}$ .  $V_m$  encontra-se deslocado de um *offset* de -1.5 V. Os sinais de  $V_{ac}$ ,  $I_{ac}$  e  $I_{L_o}$  estão sem deslocamento por *offset*. Conversor sujeito a uma carga de 306 W e  $V_o$  igual a 36,20 V. **CH1**:  $V_{ac}$ , **CH2**:  $I_{ac}$ , **CH3**:  $I_{L_o}$  e **CH4**:  $V_m$ .



(a) **CH1**: 250V/Div **CH2**: 4A/Div **CH3**: 5A/Div **CH4**: 0,5V/Div **T**: 5ms/Div Ensaio sem a aplicação do método *Feedforward Current*.



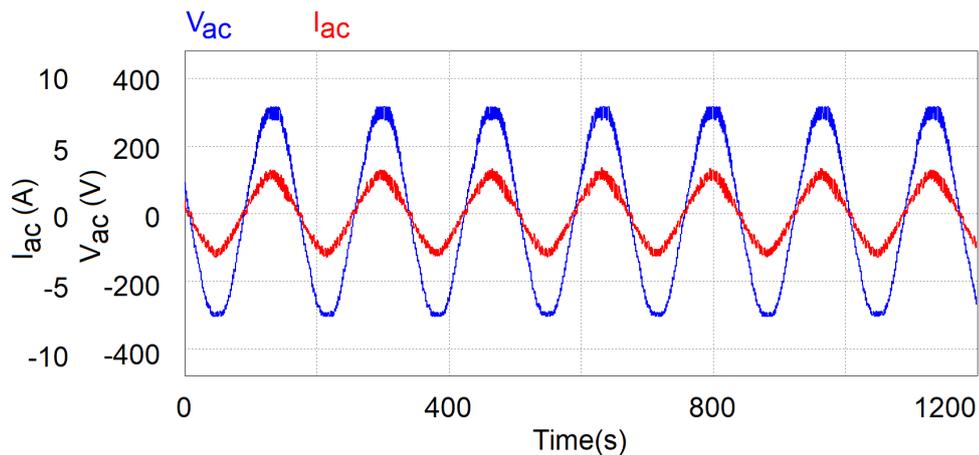
(b) **CH1**: 250V/Div **CH2**: 4A/Div **CH3**: 5A/Div **CH4**: 0,5V/Div **T**: 5ms/Div Ensaio com a aplicação do método *Feedforward Current*.

Fonte: Autoria própria

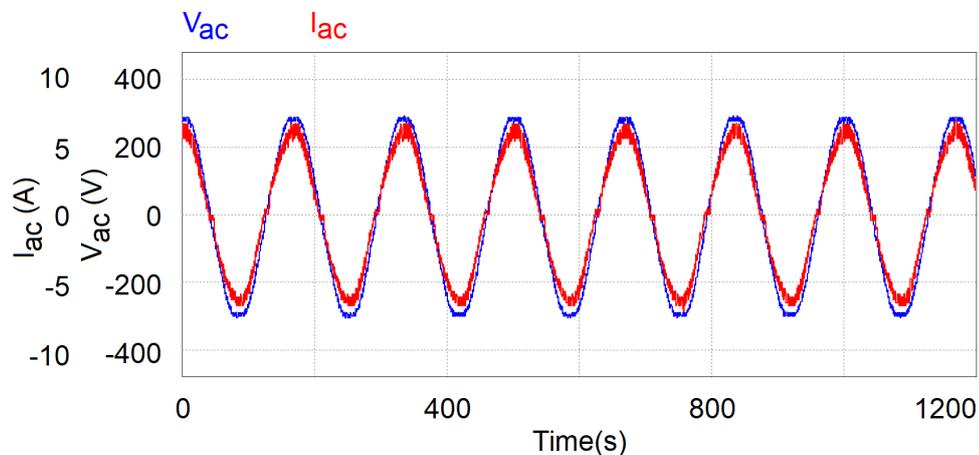
O cenário da Figura 71 foi desenvolvido a partir da coleta dos dados pelo osciloscópio

no formato *.csv*, onde  $V_o$  apresenta a magnitude de 36,20 V. De posse dos dados estes foram introduzidos no *software* PSIM e assim pôde-se calcular o FP e também gerar os devidos gráficos. O fator de potência encontrado para a Figura 71(a) é de 0,9839 e para a Figura 71(b) o valor encontrado é de 0,9932, o que está alinhado com a Figura 58, objeto da simulação numérica.

Figura 71 – Gráfico da tensão e da corrente de entrada,  $V_{ac}$  e  $I_{ac}$ , alvos para o cálculo do fator de potência em resposta à cargas de 306 W e 700 W para  $V_o$  a 36,20 V.



(a) Resposta do ANNC para uma carga de 306 W e FP com magnitude igual a 0,9839.



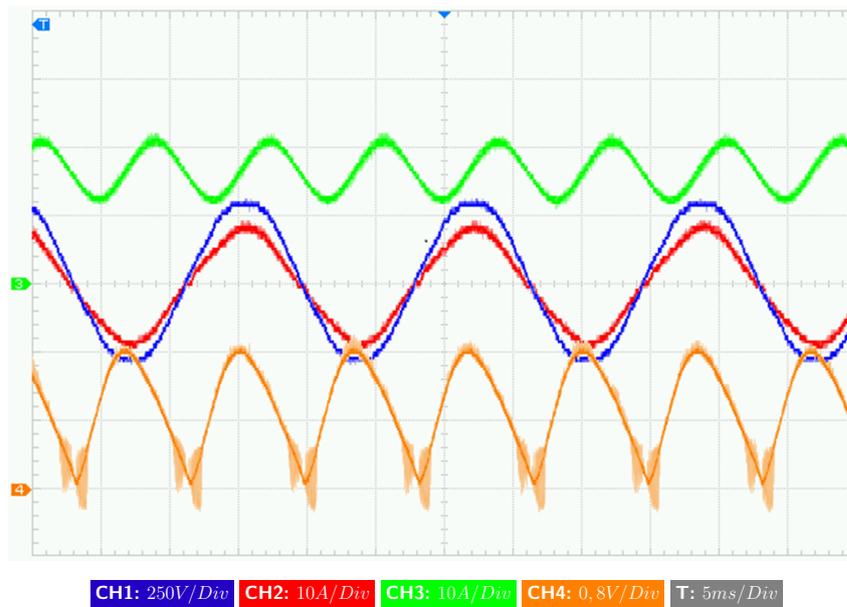
(b) Resposta do ANNC para uma carga de 700 W e FP com magnitude igual a 0,9932.

Fonte: Autoria própria - Simulador PSIM.

Na medida que a configuração da carga posiciona o conversor fora da região crítica da técnica *Feedforward Current*, possibilita ao controlador corrigir o fator de potência com maior suavidade, reflexo do que ocorre com o cenário apontado na Figura 71(b). Outro ponto de destaque a respeito do aumento de  $P_o$ , e que possui relação diretamente proporcional com a correção do fator de potência, é a correção inferida em  $V_m$ , o que de acordo com o cenário ofertado pela Figura 72 observa-se que a intensidade na inclinação de  $V_m$  é também minimizada. Ao confrontar as informações dos gráficos das Figuras 71(b) e 72 observa-se a influência do índice de modulação,  $M_i$  (definido pela Equação (49), que relaciona  $I_{ac(pico)}$  e

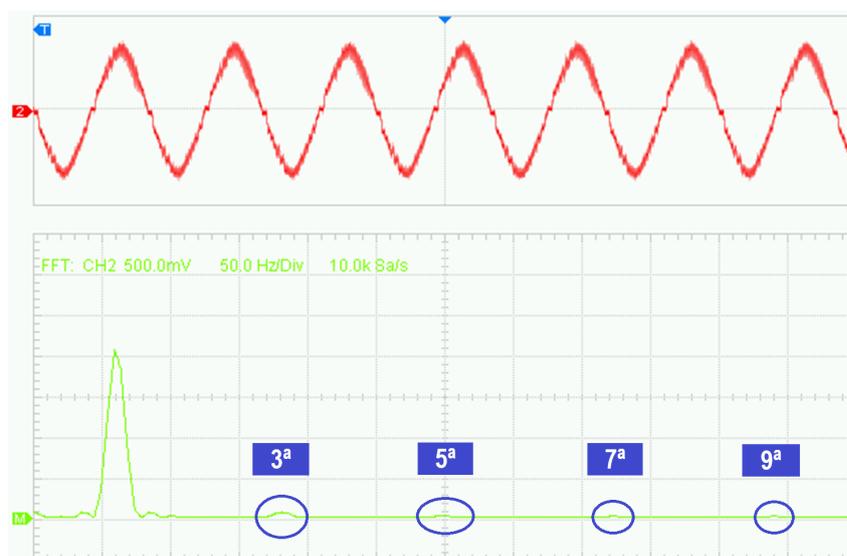
$I_o$ ), no ajuste de  $V_m$  por meio de  $\theta$  que aponta para o ângulo pelo qual a corrente de saída tangencia a corrente de entrada, tal como abordado na Seção 5.1.

Figura 72 – Resposta do ANNC para uma carga de 1050 W e FP com magnitude igual a 0,9917 com  $V_o$  igual a 60 V.  $V_m$  encontra-se deslocado de um *offset* de -2,4 V. Os sinais de  $V_{ac}$ ,  $I_{ac}$  e  $I_{L_o}$  estão sem deslocamento por *offset*. **CH1**:  $V_{ac}$ , **CH2**:  $I_{ac}$ , **CH3**:  $I_{L_o}$  e **CH4**:  $V_m$ .



Fonte: Autoria própria.

Figura 73 – Espectro harmônico da corrente de entrada lida pelo osciloscópio para uma carga de 306 W e  $V_o$  com magnitude igual a 36,20 V.

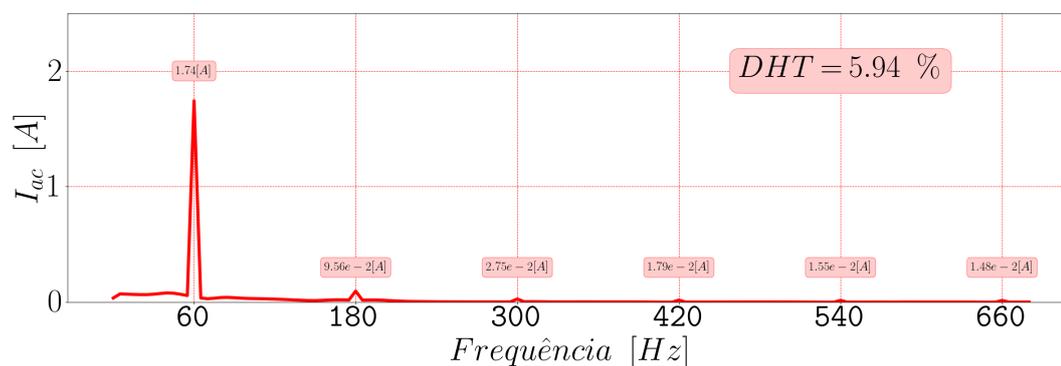


Fonte: Autoria própria.

O cenário disposto na Figura 73 apresenta o conteúdo harmônico de  $I_{ac}$  capturado pelo osciloscópio, onde a frequência central encontra-se ajustada para 300 Hz (5ª harmônica). De acordo com F Pottker Souza e Barbi (1999), como elencado no contexto da Figura 70, o ponto crítico da técnica *Feedforward Current* está situado onde  $I_{L_o}$  é igual ou ligeiramente menor que o valor absoluto de  $I_{ac}$ , o qual ocorre onde  $P_o$  está sobre o seu limite inferior. Devido a essa característica, definiu-se que a configuração para avaliar o controlador da perspectiva da DHT, quanto da perspectiva do FP, trata mesma configuração do cenário exposto na Figura 70, ponto no qual o controlador será mais exigido.

A partir da Figura 74, a qual reflete as mesmas informações que a Figura 73 (não encontra-se visível a 11ª harmônica de  $I_{ac}$ ), porém com maior riqueza de detalhes, o que corrobora para ampliar a percepção da eficiência do controlador, em especial pela DHT encontrada para as harmônicas de 3ª a 11ª ordem, com magnitude de 5,94%. De acordo com o que se observa, fica claro que o ANNC cumpre com o proposto.

Figura 74 – Espectro harmônico da corrente de entrada numericamente processada com os dados utilizados na geração do gráfico da Figura 73.

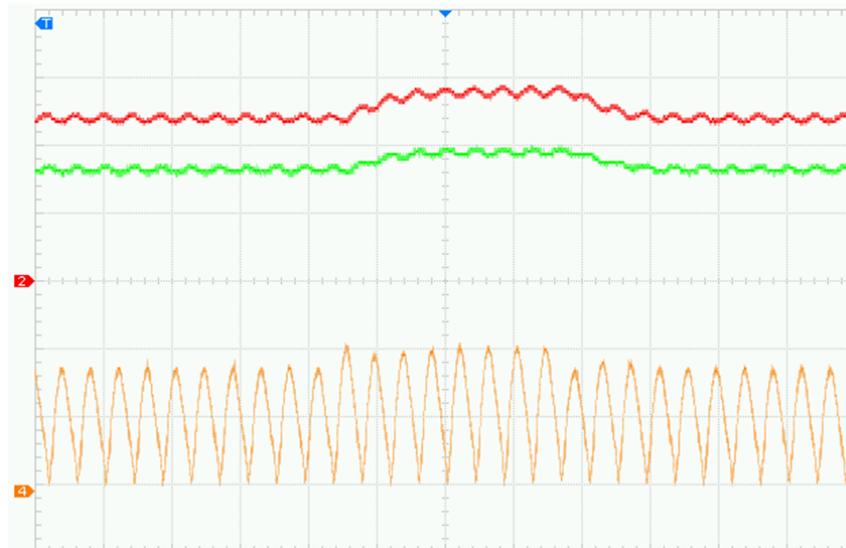


Fonte: Autoria própria.

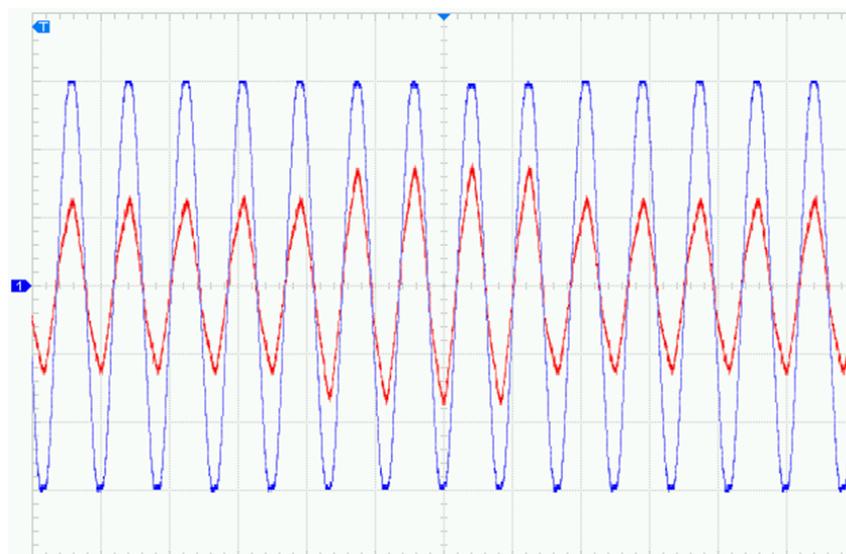
O cenário da Figura 75 reflete o cenário da Figura 60, onde o ANNC corrige  $V_m$  na medida que  $V_{ref}$  passa por uma alteração abrupta em seu valor, com reflexo imediato em  $V_{ac}$  e  $I_{ac}$ . De acordo com a Figura 75(b) não se observa deformação em  $I_{ac}$ , o que aponta para a manutenção do fator de potência próximo a unidade, ou seja, 100%. Percebe-se que no momento em que  $V_{ref}$  salta de 36 V para 43 V e depois retorna para 36 V, a potência na carga varia de 306 W para 370 W e o ANNC ajusta  $V_o$  e a mantém estável após as transições em  $V_{ref}$ .

Os gráficos apresentados pelas Figuras 76 e 77 fazem parte do mesmo cenário, o qual relaciona as grandezas  $V_m$ ,  $V_o$ ,  $I_o$ ,  $V_{ac}$  e  $I_{ac}$  a uma variação abrupta em  $P_o$ . O papel da ANNC é o controle do fator de potência, bem como manter a magnitude de  $V_o$  e  $I_o$  com baixa distorção. O cenário em questão evidencia as características do que se observa na Figura

Figura 75 – Resposta do ANNC ao degrau em  $V_{ref}$ . Na Figura 75(a)  $V_m$  encontra-se deslocado por um *offset* de -1.5 mV,  $V_o$  e  $I_{L_o}$  não encontram-se deslocados por *offset*. Na Figura 75(b), tem-se  $V_{ac}$  e  $I_{ac}$  sem deslocamento por *offset*. Conversor sujeito a variação em  $P_o$  entre 306 W e 370 W. **CH1**:  $V_{ac}$ , na Figura 75(a) **CH2**:  $V_o$  e na Figura 75(b) **CH2**:  $I_{ac}$ , **CH3**:  $I_{L_o}$  e **CH4**:  $V_m$ .



(a) **CH2**: 15V/Div **CH3**: 5A/Div **CH4**: 0,5V/Div **T**: 20ms/Div

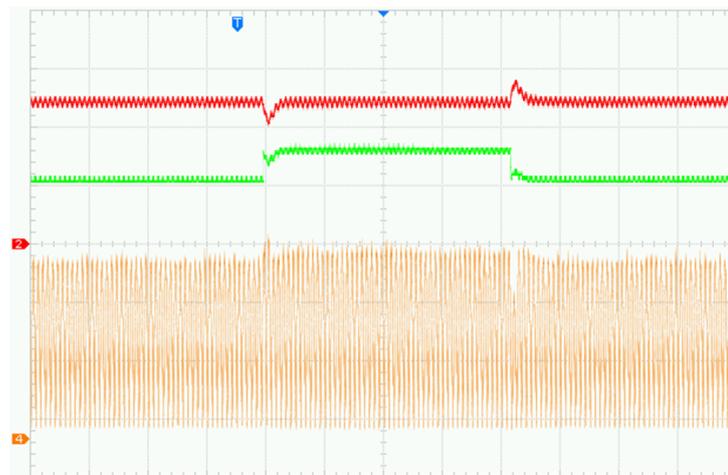


(b) **CH1**: 100V/Div **CH2**: 2A/Div **T**: 10ms/Div

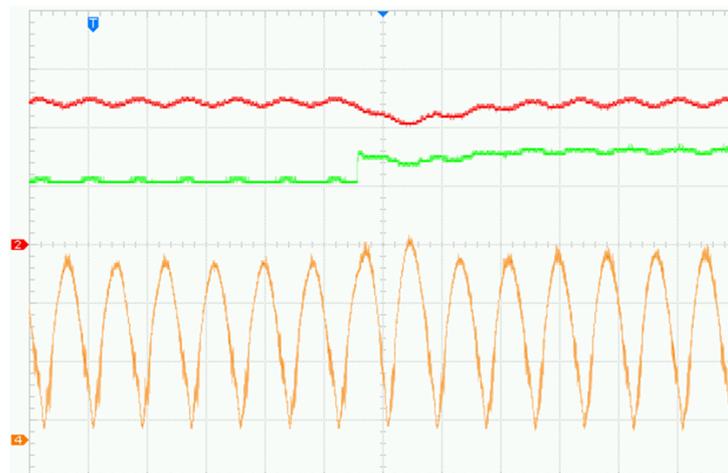
Fonte: Autoria própria.

61 para a simulação numérica do ANNC. De modo semelhante ao que ocorre no cenário da Figura 61, no momento em que  $P_o$  altera-se abruptamente, haja visto que trata-se de um controle em tempo real,  $I_{ac}$  é imediatamente corrigida. O reflexo da correção é percebido no próximo meio ciclo da rede, o que também pode ser observado na Figura 77. Portanto, fica claro a robustez do ANNC ao manter tanto  $V_o$  sem sobressaltos significativos, quanto  $I_{ac}$  sem deformação após as transições em  $P_o$ .

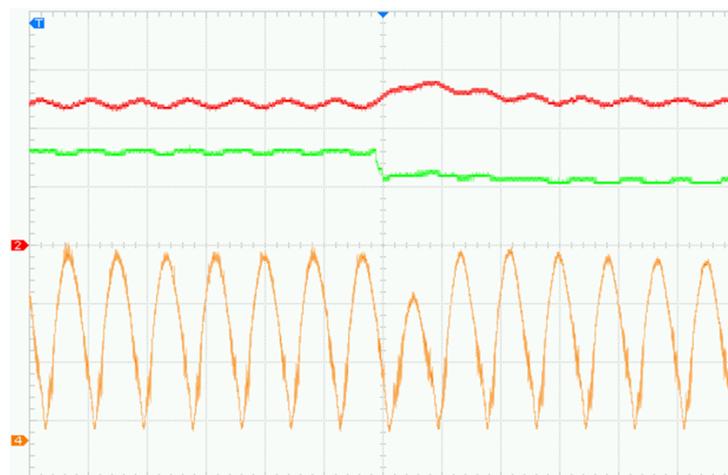
Figura 76 – Resposta do ANNC frente ao degrau em  $P_o$ , alternando entre 374 W e 568 W.  $V_m$  deslocado por um *offset* de -1.0 V. **CH2**:  $V_o$ , **CH3**:  $I_o$  e **CH4**:  $V_m$ .



(a) **CH2: 15V/Div** **CH3: 10A/Div** **CH4: 0,3V/Div** **T: 100ms/Div** Correção de  $V_m$  para um degrau de 194 W em  $P_o$ .



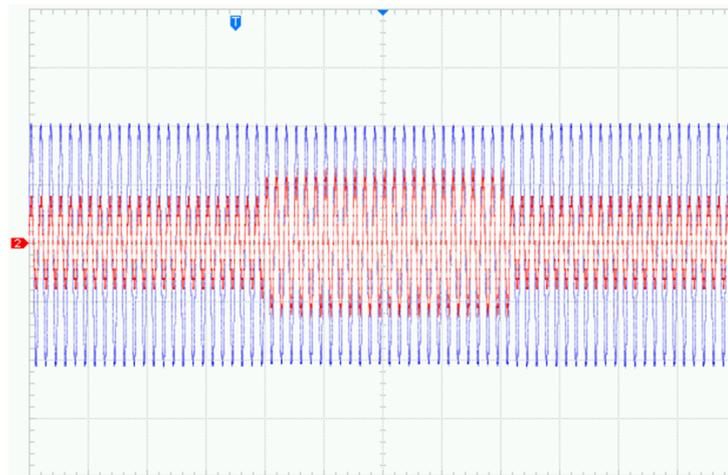
(b) **CH2: 15V/Div** **CH3: 10A/Div** **CH4: 0,3V/Div** **T: 10ms/Div** Correção de  $V_m$  para um degrau em  $P_o$ , onde  $P_o$  salta de 374 W para 568 W.



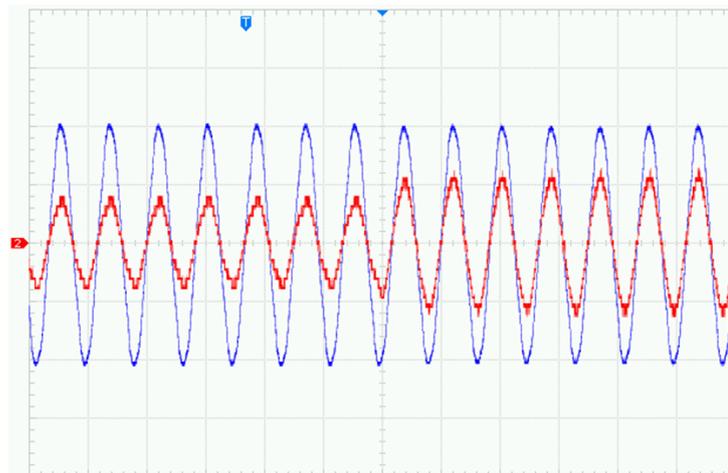
(c) **CH2: 15V/Div** **CH3: 10A/Div** **CH4: 0,3V/Div** **T: 10ms/Div** Correção de  $V_m$  para um degrau em  $P_o$ , onde  $P_o$  decai de 568 W para 374 W.

Fonte: Autoria própria.

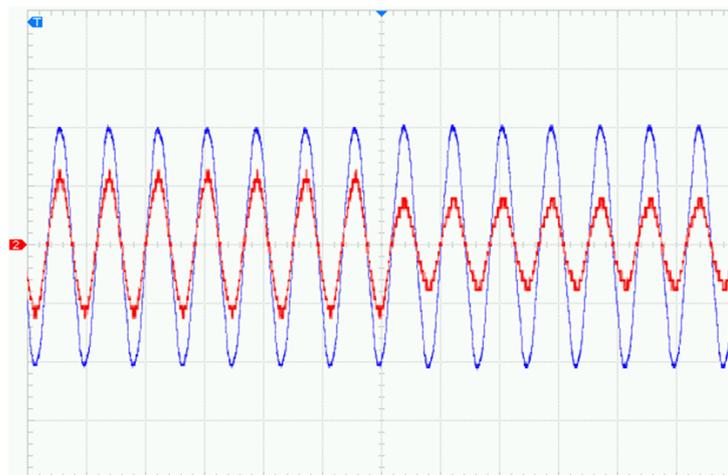
Figura 77 – Resposta do ANNC frente ao degrau em  $P_o$ , alternando entre 374 W e 568 W.  
**CH1**:  $V_{ac}$  e **CH2**:  $I_{ac}$ .



(a) **CH1**: 150V/Div **CH2**: 4A/Div **T**: 100ms/Div Correção de  $V_m$  para um degrau de 194 W em  $P_o$ .



(b) **CH1**: 150V/Div **CH2**: 4A/Div **T**: 10ms/Div Reflexo do degrau de  $P_o$  em  $I_{ac}$  para o salto de 374 W para 568 W.



(c) **CH1**: 150V/Div **CH2**: 4A/Div **T**: 10ms/Div Reflexo do degrau de  $P_o$  em  $I_{ac}$  para o decaimento de 568 W para 374 W.

Fonte: Autoria própria.

## 6.4 CONCLUSÃO

No cenário desenvolvido na Figura 69, o experimento evidenciou para uma carga de 525 W, que o ANNC está apto para manter tanto  $V_o$  quanto  $I_o$  constantes na inicialização do sistema. De posse dos gráficos apresentados pela Figura 70, observa-se que o método *Feedforward Current* associado ao neurônio aditivo trata de uma proposta acertada para o ANNC. Quando se avalia a resposta do ANNC em relação ao FP, cenário apresentado na Figura 71, conclui-se que o controle por meio de RNA é robusto. A partir da análise dos cenários das Figuras 76 e 77, cenários complementares, fica claro a eficácia do ANNC ao recuperar de uma transição súbita em  $P_o$ . De posse dos resultados alcançados pelo protótipo, com destaque para os cenários apresentados pelas Figuras 69, 70, 71, 76 e 77, em detrimento dos evidenciados pela simulação numérica, é correto afirmar que o ANNC representa uma alternativa frente aos controladores clássicos no que diz respeito aos conversores Buck PFC.

## 7 CONCLUSÃO E TRABALHOS FUTUROS

Os veículos elétricos são uma realidade do mundo contemporâneo, bem como os sistemas geradores de energia, o que justifica o surgimento crescente de novas tecnologias voltadas para este segmento, dentre estas citam-se os carregadores e controladores de carga para os bancos de baterias dos sistemas de armazenamento de energia, em sua grande maioria dotados de sistemas de controle clássicos. Com o objetivo de fomentar uma contrapartida aos controladores clássicos, este trabalho apresenta uma alternativa de controlador adaptativo, definido como *Adaptive Neural Network Controller* ou ANNC, que faz uso da técnica *Feedforward Current* do indutor de saída associada ao neurônio aditivo.

No decorrer do estudo que levou ao ANNC, o conhecimento adquirido resultou nas seguintes publicações: *Instantaneous Adaptive Controller Based on Neural Network for Buck Converter* apresentado no *16th The Brazilian Power Electronics Conference - COBEP*, e o *Controlador Instantâneo Adaptativo Baseado em Rede Neural aplicado a um Conversor Boost* apresentado ao *Simpósio Brasileiro de Automação Inteligente-SBAI*. Portanto, o ANNC percorreu uma trajetória até alcançar os resultados desenvolvidos neste estudo.

Nos capítulos apresentados foram exibidos princípios de implementação, estudos, e aplicação das redes neurais Perceptron e MLP para a obtenção de um controlador adaptativo por *Feedforward Current* e neurônio aditivo para correção do fator de potência e controle da tensão de saída de um retificador Buck monofásico. Para os resultados obtidos, tanto em simulação para as arquiteturas Monocamada e MLP, quanto experimentais para a arquitetura Monocamada, o ANNC obteve êxito na manutenção do fator de potência praticamente unitário e tensão controlada na carga tanto em regime permanente quanto em algumas condições de resposta ao degrau.

No que diz respeito ao protótipo, idealizado para responder a uma carga de até 1500 W, bem como ofertar tensões com magnitudes que variam entre 20 V e 60 V, foi possível replicar os cenários do modelo de simulação numérica praticamente na sua totalidade, de maneira que pôde-se alcançar um FP de 0.9839 (considerando a região crítica de operação da técnica *Feedforward Current*) e uma DHT em  $I_{ac}$  de 5.94%, os quais representam resultados positivos para o conversor Buck PFC. Também vale ressaltar que, tanto nos testes por simulação numérica, quanto nos testes experimentais, o ANNC recuperou-se do degrau na carga sem alteração significativa em  $V_o$ .

### 7.1 TRABALHOS FUTUROS

No decorrer do estudo do ANNC observou-se que muitos pontos poderiam ser ampliados, quiçá modificados, com o objetivo de melhorar a resposta do controlador. Estes pontos serão discutidos a seguir.

A primeira consideração a se fazer é a adaptação do ANNC para a topologia trifásica do Buck PFC. Como exemplo, pode-se avaliar a topologia descrita na introdução deste estudo,

o conversor Buck PFC trifásico modelado a partir de três braços monofásicos, como consta na Figura 4. Com o objetivo de atestar a viabilidade da aplicação do ANNC ao Buck da Figura 4, com poucos ajustes no diagrama esquemático foi possível simular com o PSIM a aplicação do ANNC ao Buck PFC trifásico. No entanto, é necessário um estudo mais abrangente sobre a viabilidade de um protótipo. Os resultados da simulação podem ser acompanhados no Apêndice E.

Cabe também a investigação de outras arquiteturas de redes neurais aplicadas ao Buck PFC, bem como outras topologias de conversores, tais como o Boost PFC. Como sugestão de topologias de RNAs que podem ser trabalhadas nesse sentido, trata das RNAs com Aprendizagem Recorrente em Tempo Real (ARTR), a qual representa uma categoria de RNAs, e da *Fully Connected Cascade* (FCC), que também pode representar uma opção interessante para o ANNC, haja visto o desempenho frente a outras arquiteturas como demonstrado por Wilamowski (2009).

Sugere-se também a substituição do módulo de controle NUCLEO-STM32L491RG pelo TI LaunchPad F28379. A sugestão para a troca do processador STM32L491RG pelo módulo F28379 está assegurado na premissa do uso do ANNC em topologias de conversores trifásicos bem como arquiteturas de RNAs que exijam maior poder de processamento em tempo real, por exemplo, as arquiteturas MLP, ARTR e FCC. A troca não afetaria, ou afetaria pouco, o novo *firmware*. Isso é possível porque o *firmware* foi desenvolvido utilizando C ANSI, sem a utilização de bibliotecas personalizadas.

Estimula-se a investigar o fato do instante que há a estabilização na atualização das taxas de aprendizado, que por dedução, a rede se encontraria treinada e os pesos não demandariam mais de atualização, assim, a priori, poderia utilizar apenas o modo de computação para frente (*forward*), o que representaria um ganho de desempenho. O que é justificado pelo o que se observa na Seção 4.5.4, onde na medida que o número de neurônios é ampliado o ajuste promovido pelo algoritmo RMSProp à taxa de aprendizado tende a estabilizar e a taxa de atualização do *bias* e demais pesos praticamente se equiparam.

Outrossim, seria o estudo do ANNC operando no modo *preditivo*, onde o ANNC em *tempo real* seria utilizado para gerar os devidos dados de treinamento. Os dados de treinamento poderiam ser exportados via *.csv* a partir do PSIM e processados por algum *software* matemático equipado com algum algoritmo para treinamento da RNA em questão. Após o treinamento da rede, com os pesos ajustados, a matriz de pesos seria reinserida no PSIM, no que diz respeito a simulação numérica, ou no protótipo, e apenas o modo *forward* seria executado.

## REFERÊNCIAS

AGENCY, International Energy. Global EV outlook, 2019.

ARRUDA, Luiz Fernando Marquez; VIEIRA LESSA, Moises Ferber de; GREFF, Diego Santos. Aplicação de redes neurais artificiais para rastreamento de ponto de máxima potência em painel solar aplicado a um conversor Cúk. **Anais da Sociedade Brasileira de Automática**, v. 2, n. 1, 2020.

BARBI, Ivo. Eletrônica de potência. Ed. do Autor, 2006.

BARBI, Ivo. Modelagem de conversores CC-CC empregando modelo médio em espaço de estados. **Edição do autor. Florianópolis-SC**, 2015.

BARBI, Ivo; MARTINS, Denizar Cruz. **Conversores CC-CC Básicos não Isolados**. 4. ed. CEP 88.040-970, Florianópolis - SC: [s.n.], 2000. ISBN 85-905203-2-3.

CLEVERT, Djork-Arné; UNTERTHINER, Thomas; HOCHREITER, Sepp. Fast and accurate deep network learning by exponential linear units (elus). **arXiv preprint arXiv:1511.07289**, 2015.

DACOL, Rodrigo Patrício *et al.* Carregador de baterias não isolado com retificador PFC semi-bridgeless boost, 2019.

DE, Soham; MUKHERJEE, Anirbit; ULLAH, Enayat. Convergence guarantees for RMSProp and ADAM in non-convex optimization and an empirical comparison to Nesterov acceleration. **arXiv preprint arXiv:1807.06766**, 2018.

DICKERMAN, Larry; HARRISON, Jessica. A new car, a new grid. **IEEE power and energy magazine**, IEEE, v. 8, n. 2, p. 55–61, 2010.

FAWCETT, Tom. An introduction to ROC analysis. **Pattern recognition letters**, Elsevier, v. 27, n. 8, p. 861–874, 2006.

GREFF, Diego Santos. **Retificador buck trifásico unidirecional PWM isolado em alta-frequência por único estágio**. Mar. 2009. Tese (Doutorado) – Universidade Federal de Santa Catarina.

HALLIDAY, David; RESNICK, Robert; KRANE, Kenneth S. **Physics, Volume 2**. [S.l.]: John Wiley & Sons, 2010.

HART, Daniel W. **Eletrônica de potência: análise e projetos de circuitos**. [S.l.]: McGraw Hill Brasil, 2016.

HAYKIN, S. **Redes Neurais - Princípios e prática**. 2. ed. Porto Alegre: Bookman, 2001. P. 899. ISBN 978-85-7307-718-6.

HEBB, Donald Olding. **The organisation of behaviour: a neuropsychological theory**. [S.l.]: Science Editions New York, 1949.

HIRACHI, Katsuya; IWADE, T; SHIBAYAMA, K. A specific control implementation on back-type active power filtering converters. *In*: IEEE. PROCEEDINGS of INTELEC 95. 17th International Telecommunications Energy Conference. [S.l.: s.n.], 1995. P. 444–449.

HORNIK, Kurt; STINCHCOMBE, Maxwell; WHITE, Halbert. Universal approximation of an unknown mapping and its derivatives using multilayer feedforward networks. **Neural networks**, Elsevier, v. 3, n. 5, p. 551–560, 1990.

HOROWITZ, Paul; HILL, Winfield; ROBINSON, Ian. **The art of electronics**. [S.l.]: Cambridge university press Cambridge, 1989. v. 2.

JOOS, G; DE FREIGE, M; DUBOIS, Maxime. Design and simulation of a fast charging station for PHEV/EV batteries. *In*: IEEE. 2010 IEEE Electrical Power & Energy Conference. [S.l.: s.n.], 2010. P. 1–5.

KOLAR, Johann W; FRIEDLI, Thomas. The essence of three-phase PFC rectifier systems. *In*: IEEE. 2011 IEEE 33rd International Telecommunications Energy Conference (INTELEC). [S.l.: s.n.], 2011. P. 1–27.

KUROKAWA, Fujio; UENO, Kimitoshi; MARUTA, Hidenori; OSUGA, Hiroyuki. A new control method for dc-dc converter by neural network predictor with repetitive training. *In*: IEEE. 2011 10th International Conference on Machine Learning and Applications and Workshops. [S.l.: s.n.], 2011. P. 292–297.

LACROIX, Samantha; LABOURÉ, Eric; HILAIRET, Mickaël. An integrated fast battery charger for electric vehicle. *In*: IEEE. 2010 IEEE Vehicle Power and Propulsion Conference. [S.l.: s.n.], 2010. P. 1–6.

- LUO, Fang Lin; YE, Hong. Switched inductor two-quadrant DC/DC converter with neural network control. *In: IEEE. PROCEEDINGS of the IEEE 1999 International Conference on Power Electronics and Drive Systems. PEDS'99 (Cat. No. 99TH8475). [S.l.: s.n.], 1999. P. 1114–1119.*
- LUO, Zhi-Quan. On the convergence of the LMS algorithm with adaptive learning rate for linear feedforward networks. **Neural Computation**, MIT Press One Rogers Street, Cambridge, MA 02142-1209, USA journals-info . . . , v. 3, n. 2, p. 226–245, 1991.
- MADDALENO, F. Computer simulation of a neural network controlled buck converter. *In: IEEE. PROCEEDINGS of 1994 IEEE Workshop on Computers in Power Electronics. [S.l.: s.n.], 1994. P. 205–208.*
- MARTIGNONI, Alfonso. **Transformadores**. [S.l.]: Editora Globo, 2012.
- MARTINS, Denizar Cruz. **Conversores CC-CC Básicos Isolados**. CEP 88.040-970, Florianópolis - SC: [s.n.], 2000. ISBN 978-85-905203-3-7.
- MARUTA, Hidenori; MOTOMURA, Masashi; UENO, Kimitoshi; KUROKAWA, Fujio. Reference modification control DC-DC converter with neural network predictor. *In: IEEE. 2012 IEEE 13th Workshop on Control and Modeling for Power Electronics (COMPEL). [S.l.: s.n.], 2012. P. 1–4.*
- MC LYMAN, CW. **Transformer and Inductor Design Handbook. 8a Edição**. [S.l.]: Nova York: Editora Marcel Dekker, 1998.
- MCCULLOCH, Warren S; PITTS, Walter. A logical calculus of the ideas immanent in nervous activity. **The bulletin of mathematical biophysics**, Springer, v. 5, n. 4, p. 115–133, 1943.
- MITCHELL, Tom M. Artificial neural networks. **Machine learning**, McGraw-Hill New York, v. 45, p. 81–127, 1997.
- MOHAGHEGHI, Salman; HARLEY, Ronald G; HABETLER, Thomas G; DIVAN, Deepak. Condition monitoring of power electronic circuits using artificial neural networks. **IEEE Transactions on power electronics**, IEEE, v. 24, n. 10, p. 2363–2367, 2009.
- NIZAMI, Tousif Khan; MAHANTA, Chitrallekha. Adaptive backstepping control for DC-DC buck converters using Chebyshev neural network. *In: IEEE. 2014 annual IEEE india conference (INDICON). [S.l.: s.n.], 2014. P. 1–5.*

OVIEDO, J.J.E.; BOELEN, T.; OVERSCHEE, P. van. Robust advanced PID control (RaPID): PID tuning based on engineering specifications. **IEEE Control Systems Magazine**, v. 26, n. 1, p. 15–19, 2006. DOI: 10.1109/MCS.2006.1580148.

POMILIO, José Antenor. Pré-reguladores de Fator de Potência. **Publicação FEE**, v. 3, p. 95, 2007.

RASHID, Muhammad H. **Power electronics handbook**. [S.l.]: Butterworth-Heinemann, 2017.

REDDY, R Vijava Kumar; RAO, B Srinivasa; RAJU, K Prudvi. Handwritten Hindi digits recognition using convolutional neural network with RMSprop optimization. *In*: IEEE. 2018 Second International Conference on Intelligent Computing and Control Systems (ICICCS). [S.l.: s.n.], 2018. P. 45–51.

ROSENBLATT, Frank. The perceptron: a probabilistic model for information storage and organization in the brain. **Psychological review**, American Psychological Association, v. 65, n. 6, p. 386, 1958.

ROSOLEM, MFNC. Bateria de Lítio-íon Estado da Arte. **II Seminário Sobre Lítio–Brasil**, 2016.

RUMELHART, David E; HINTON, Geoffrey E; WILLIAMS, Ronald J. Learning representations by back-propagating errors. **nature**, Nature Publishing Group, v. 323, n. 6088, p. 533–536, 1986.

SAADATMAND, Sepehr; SHAMSI, Pourya; FERDOWSI, Mehdi. The Voltage Regulation of a Buck Converter Using a Neural Network Predictive Controller. *In*: IEEE. 2020 IEEE Texas Power and Energy Conference (TPEC). [S.l.: s.n.], 2020. P. 1–6.

SILVA, Carlúcio Pereira; ARRUDA, Luiz Fernando; GREFF, Diego Santos. Instantaneous Adaptive Controller Based on Neural Network for Buck Converter. *In*: IEEE EXPLORER. PROCEEDINGS of COBEP 21. 16th The Brazilian Power Electronics Conference (COBEP). [S.l.: s.n.], 2021. P. 258–259.

SILVA, Carlúcio Pereira da; ARRUDA, Luiz Fernando Marquez; GREFF, Diego Santos. Controlador Instantâneo Adaptativo Baseado em Rede Neural Aplicado a um Conversor Boost. *In*: SBAI, 1. SIMPÓSIO Brasileiro de Automação Inteligente-SBAI. [S.l.: s.n.], 2021.

SOUZA, F Pottker; BARBI, Ivo. A unity power factor buck pre-regulator with feedforward of the output inductor current. *In: IEEE. APEC'99. Fourteenth Annual Applied Power Electronics Conference and Exposition. 1999 Conference Proceedings (Cat. No. 99CH36285). [S.l.: s.n.], 1999. P. 1130–1135.*

SOUZA, Fabiana Pottker de *et al.* Correção do fator de potência para instalações de baixa potência empregando filtros ativos. Florianópolis, SC, 2000.

SPIAZZI, G. Analysis of buck converters used as power factor preregulators. *In: IEEE. PESC97. Record 28th Annual IEEE Power Electronics Specialists Conference. Formerly Power Conditioning Specialists Conference 1970-71. Power Processing and Electronic Specialists Conference 1972. [S.l.: s.n.], 1997. P. 564–570.*

STMICROELECTRONICS. **STM32 Nucleo-64 development board with STM32F446RE MCU, supports Arduino and ST morpho connectivity.** Disponível em: [www.gta.ufrj.br/grad/09\\_1/versao-final/virtualizacao/](http://www.gta.ufrj.br/grad/09_1/versao-final/virtualizacao/).

TARDIFF, Dale; BARTON, TH. A summary of resonant snubber circuits for transistors and GTOs. *In: IEEE. CONFERENCE Record of the IEEE Industry Applications Society Annual Meeting, [S.l.: s.n.], 1989. P. 1176–1180.*

TIELEMAN, Tijmen; HINTON, Geoffrey *et al.* Lecture 6.5-rmsprop: Divide the gradient by a running average of its recent magnitude. **COURSERA: Neural networks for machine learning**, v. 4, n. 2, p. 26–31, 2012.

UTOMO, Wahyu Mulyo; BAKAR, A; AHMAD, M; TAUFIK, T; HERIANSYAH, R. Online learning neural network control of buck-boost converter. *In: IEEE. 2011 IEEE Eighth International Conference on Information Technology: New Generations. [S.l.: s.n.], 2011. P. 485–489.*

WALDEN, Robert H. Analog-to-digital converter survey and analysis. **IEEE Journal on selected areas in communications**, IEEE, v. 17, n. 4, p. 539–550, 1999.

WIDROW, Bernard; HOFF, Marcian E. **Adaptive switching circuits.** [S.l.], 1960.

WIDROW, Bernard; MCCOOL, John; BALL, Michael. The complex LMS algorithm. **Proceedings of the IEEE**, IEEE, v. 63, n. 4, p. 719–720, 1975.

---

WILAMOWSKI, Bogdan M. Neural network architectures and learning algorithms. **IEEE Industrial Electronics Magazine**, IEEE, v. 3, n. 4, p. 56–63, 2009.

ZAHEER, Manzil; REDDI, Sashank; SACHAN, Devendra; KALE, Satyen; KUMAR, Sanjiv. Adaptive methods for nonconvex optimization. **Advances in neural information processing systems**, v. 31, 2018.

## APÊNDICE A – COMPROVAÇÃO DO MÉTODO

Esta seção deste documento está a cargo da demonstração e comprovação do método proposto, o qual destaca a característica do ANNC como aproximador de funções em tempo real.

A literatura aponta que o perceptron, no seu formato original, passa por treinamento prévio segundo uma amostra de um *dataset* que define os dados de um problema, para posteriormente ser apresentado aos demais dados do *dataset*. Neste formato, a matriz de pesos,  $w_{kj}$ , do perceptron não é atualizada depois do treinamento. De acordo com Haykin (2001), no que diz respeito a sua concepção original, o perceptron não é capaz de resolver, por exemplo, o problema do XOR, onde ele não consegue definir o hiperplano de separação entre as classes que envolvem o problema.

Considerando a configuração original do perceptron para o ANNC, seria impossível alcançar os resultados observados na seção 4.4. Contudo, devido a configuração *de tempo real* do ANNC, onde a sua matriz de pesos,  $w_{kj}$ , é atualizada a cada iteração do algoritmo, lhe confere, de modo geral, a característica de não-linearidade.

A não-linearidade geral do ANNC, que será demonstrada a seguir, na seção A.1, é alcançada devido a atualização da sua matriz de pesos a cada iteração do algoritmo, onde tem-se um hiperplano de separação das classes do problema. Se a questão for observada segundo um plano 2D, onde cada hiperplano estaria associado a uma semi-reta, a cada iteração do algoritmo ter-se-ia a formação interligada de semi-retas, e como resultado geral um modelo não-linear para o ANNC.

### A.1 O ANNC COMO APROXIMADOR DE FUNÇÕES

O ANNC pode ser encarado como um aproximador de funções, haja visto que a sua arquitetura é baseada numa estrutura de mapeamento não-linear de entrada-saída, onde a função de ativação,  $\varphi(\cdot)$ , possui características de continuidade não-constante, é limitada e monotonamente crescente, o que está de acordo com o Teorema da Aproximação Universal, como afirma Haykin (2001):

Suponha que  $\varphi(\cdot)$  seja uma função contínua não-constante, limitada e monotonamente crescente. Suponha que  $I_{m_0}$  represente um hipercubo unitário  $[0, 1]^{m_0}$  de dimensão  $m_0$ . O espaço das funções contínuas em  $I_{m_0}$  é representado por  $C(I_{m_0})$ . Então, dada qualquer função  $f(\cdot) \in C(I_{m_0})$  e  $\epsilon > 0$ , existe um inteiro  $M$  e conjuntos de constantes reais  $\alpha_i, b_i$  e  $w_{ij}$ , onde  $i = 1, \dots, M$  e  $j = 1, \dots, m_0$  tal que podemos definir

$$F(x_1, \dots, x_{m_0}) = \sum_{i=1}^M \alpha_i \varphi \left( \sum_{j=1}^{m_0} w_{ij} x_j + b_i \right) \quad (71)$$

como uma aproximação da função  $f(\cdot)$ ; isto é,

$$|F(x_1, \dots, x_{m_0}) - f(x_1, \dots, x_{m_0})| < \epsilon$$

considerando todo  $x_1, x_2, \dots, x_{m_0}$  que se encontre no espaço de entrada.

Portanto, a Equação (71) representa uma rede neural do tipo multicamadas com seus seus parâmetros descritos a seguir:

1. A rede possui  $m_0$  nós de entrada, uma única camada oculta, a qual tem  $m_1$  neurônios, de modo que as entradas são identificadas pelas variáveis  $x_i, \dots, x_{m_0}$ .
2.  $i$  é o neurônio oculto com pesos sinápticos  $w_{i_1}, \dots, w_{m_0}$  e  $b_i$  representa o bias.
3. A saída da rede é composta pelas saídas dos neurônios ocultos, sendo que  $\alpha_1, \dots, \alpha_{m_1}$  representam os pesos sinápticos da camada de saída.

A aproximação definida pelo teorema tem como base a Equação (71), onde esta representa sua estrutura fundamental. O teorema é um teorema existencial, quer dizer que a justificativa matemática que o implica trata de uma aproximação de uma função contínua arbitrária o que exclui uma representação exata. A principal afirmação do teorema informa que uma rede neural com apenas uma camada oculta bastaria para computar uma aproximação  $\epsilon$  uniforme para um conjunto de entradas  $x_1, \dots, x_{m_0}$  considerando uma saída desejada  $f(x_1, \dots, x_{m_0})$  (HAYKIN, 2001).

No que diz respeito à aproximação de funções, a utilização do algoritmo *error back-propagation* fornece uma propriedade adicional para RNAs definidas com funções de ativação suaves, podem aproximar funções de um arranjo entrada-saída não conhecido, que são diferenciáveis por partes, como um sistema composto por uma derivada generalizada.

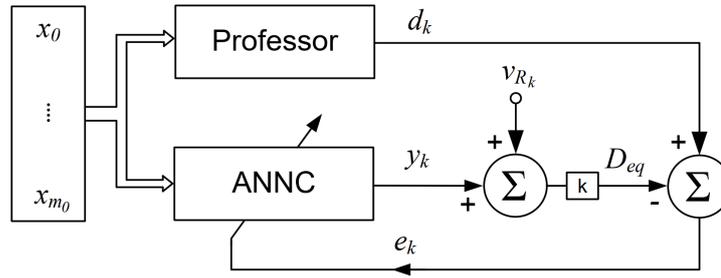
De acordo Haykin (2001), tal proposta foi originalmente demonstrada por Hornik *et al.* (1990) e que representou um marco para a ciência, haja visto que até então não existia uma formalização teórica para aproximação de funções e de suas derivadas por meio de redes neurais. Nesse sentido o ANNC destaca-se por utilizar o algoritmo *Backpropagation* e a função de ativação ELU.

Outro aspecto importante é a relação entrada-saída, onde se observa o mapeamento de um espaço de entrada tido como euclidiano e com dimensão  $m_o$ , para um espaço de saída também euclidiano com dimensão  $M$ , diferenciável para funções diferenciáveis. O que se observa, no exemplo do ANNC, é a redução da dimensão do sistema de controle e, portanto a sua complexidade, pois está sendo traduzido de uma entrada com dimensão  $m_5$  ( $V_{ac}, I_{ac}, I_o, I_{L_o}$  e a entrada fixa +1) para uma dimensão  $m_1$  ( $D$ ).

A Figura 78 ilustra o diagrama de blocos para mapeamento entrada-saída segundo o Teorema da Aproximação Universal, o qual encontra-se aplicado ao contexto do neurônio aditivo que descreve o comportamento do ANNC como uma entidade que aproxima funções.

Dessa forma, a partir da Equação (71), considera-se que as Equações (72) e (73), nessa ordem, representam as saídas obtida (ou calculada) e a desejada para o ANNC.

Figura 78 – Diagrama de blocos do aproximador de funções ANNC.



Fonte: Autoria própria.

$$F(x_1, \dots, x_{m_0}) = y_k \quad (72)$$

$$f(x_1, \dots, x_{m_0}) = d_k \quad (73)$$

No entanto, a representação da aproximação,  $\epsilon$ , que reflete o limite para o erro,  $e_k$ , deve considerar o sinal analógico,  $v_{R_k}$ , que simboliza o atributo temporal característico do neurônio aditivo. Sendo assim  $F(\cdot)$  é reescrita como uma função  $G(\cdot)$  composta de  $x_1, \dots, x_{m_0}$ ,  $v_{R_k}$  e  $k$ , o que pode ser conferido na Equação (74). O parâmetro  $k$  trata de um fator de correção aplicado ao sistema, o qual será abordado com mais detalhes na Seção A.2.

$$G((x_1, \dots, x_{m_0}), v_{R_k}, k) = D_{eq} \quad (74)$$

A Equação (75) determina os parâmetros para  $\epsilon$ , levando em conta o neurônio aditivo.

$$|(y_k + v_{R_k})k - d_k| < \epsilon \leftrightarrow |D_{eq} - d_k| < \epsilon \quad (75)$$

Tendo em consideração que  $d_k$  corresponde ao valor de referência para a razão cíclica equivalente, por conseguinte,  $f(x_1, \dots, x_{m_0})$  expressa uma função constante no tempo, à saber  $d_k$ , assim o ANNC na perspectiva do professor mapeia as entradas da rede neural para a tensão de saída esperada. Dessa forma, ao longo do processamento, o ANNC aproxima  $D_{eq}$  de  $d_k$  ao ponto de  $e_k \approx 0$ , fator que o caracteriza como um aproximador de funções.

## A.2 VALIDAÇÃO DE $V_{R_o}$ COMO ATRIBUTO DE UM NEURÔNIO ADITIVO PARA O ANNC

A validação algébrica de  $V_{R_o}$  como parâmetro aditivo diz respeito a inserção da técnica *Feedforward Current* e da característica de neurônio aditivo ao ANNC.

A Equação (75) traduzida para o contexto dos parâmetros formais do ANNC pode ser acompanhada na Equação (76).

$$|(D_o + V_{R_o})k - D_{ref}| < \epsilon \leftrightarrow |D_{o(eq)} - D_{ref}| < \epsilon \quad (76)$$

É pertinente dizer que, ao considerar a Equação (74), que o limite dado pela Equação (77), deve ser verdadeiro para que a aproximação,  $\epsilon$ , ocorra.

$$\lim_{D_{erro} \rightarrow 0} G((x_1, \dots, x_{m_0}), v_{R_k}, k) = d_k \quad (77)$$

Haja visto que a Equação (74) é composta, para o limite apontado na Equação (77), os seguintes pontos precisam ser considerados:

1. Como alvo do ANNC, na medida que o processamento ocorre, é minimizar o erro,  $D_{erro}$ , e assim garantir a aproximação,  $\epsilon$ , entre  $D_{ref}$  e  $D_{o(eq)}$ , para tal considera-se a existência do limite definido pela Equação (78) como verdadeiro.

$$\lim_{D_{erro} \rightarrow 0} |D_{o(eq)} - D_{ref}| = 0 \quad (78)$$

2. Como admiti-se que o limite dado pela Equação (78) é válido, então o limite visto na Equação (79) também é verdade.

$$\lim_{D_{erro} \rightarrow 0} |D_{o(eq)}| = |D_{ref}| \quad (79)$$

3. Dado que o limite apontado na Equação (79) é válido, conseqüentemente o limite denotado na Equação (80) também deve ser verdade. O parâmetro  $k$  efetua uma correção no sistema, tendo em vista que  $|D_o| \equiv |V_{R_o}|$ , o que justifica  $k = \frac{1}{2}$ .

$$\begin{aligned} \lim_{D_{erro} \rightarrow 0} |(D_o + V_{R_o})k - D_{ref}| &= 0 \\ \lim_{D_{erro} \rightarrow 0} |(D_o k + V_{R_o} k) - D_{ref}| &= 0 \\ \lim_{D_{erro} \rightarrow 0} |(D_o \frac{1}{2} + V_{R_o} \frac{1}{2}) - D_{ref}| &= 0 \\ \lim_{D_{erro} \rightarrow 0} |D_o + V_{R_o} - 2D_{ref}| &= 0 \end{aligned} \quad (80)$$

- a. A Equação (81) estende a (80), e tem como objetivo demonstrar que na medida que o limite é válido têm-se o alinhamento dos *offsets* de  $V_{R_o}$  e  $D_o$  para  $D_{ref}$ .

$$\begin{aligned} \lim_{D_{erro} \rightarrow 0} |D_o + V_{R_o} - 2D_{ref}| &= 0 \\ \lim_{D_{erro} \rightarrow 0} |D_o + V_{R_o} + (-D_{ref} - D_{ref})| &= 0 \\ \lim_{D_{erro} \rightarrow 0} |(D_o - D_{ref}) + (V_{R_o} - D_{ref})| &= 0 \end{aligned} \quad (81)$$

4. O Princípio da Superposição de Ondas informa que, onde dois sinais eletromagnéticos propagando simultaneamente, com mesma frequência angular  $w$ , mesma amplitude

$y_m$ , mesmo número de onda, por exemplo, duas ondas  $y_1(x, t) = y_m \text{sen}(kx - wt)$  e  $y_2(x, t) = y_m \text{sen}(kx - wt + \phi)$ , diferindo entre si por  $\phi = \pi$  ou  $180^\circ$ , ou seja, complemente defasados entre si, em que o pico de um está sobreposto ao vale do outro, têm-se o cancelamento mútuo dos sinais (HALLIDAY *et al.*, 2010).

Como  $V_{R_o}$  está em função de  $I_{L_o}$ , de onde advém seu comportamento senoidal, então, aplicar o Princípio da Superposição de Ondas ao termo ondulatório,  $\frac{\Delta I_o}{2} \text{sen}(2\theta)$ , de  $I_{L_o}$ , garante a validade do limite dado pela Equação (80) e, simultaneamente, o da Equação (81). Os passos a seguir caracterizam o processo para o cancelamento do termo ondulatório de  $I_{L_o}$ :

- a. A priori considera-se o termo ondulatório como duas funções distintas, uma com comportamento normal e outra deslocada por uma constante de fase definida por  $\phi$ :

$$\Delta I_{L_o}^{(1)} = \frac{\Delta I_o}{2} \text{sen}(2\theta) \quad (82)$$

$$\Delta I_{L_o}^{(2)} = \frac{\Delta I_o}{2} \text{sen}(2\theta + \phi) \quad (83)$$

$$(84)$$

- b. Aplica-se o Princípio da Superposição de Ondas a  $I_{L_o}$  na forma de  $I'_{L_o}(\theta, \phi)$ :

$$\begin{aligned} I'_{L_o}(\theta, \phi) &= I_o - \left[ \Delta I_{L_o}^{(1)} + \Delta I_{L_o}^{(2)} \right] \\ &- \left[ \frac{\Delta I_o}{2} \text{sen}(2\theta) + \frac{\Delta I_o}{2} \text{sen}(2\theta + \phi) \right] \\ &- \left[ \Delta I_o \cos\left(\frac{1}{2}\phi\right) \right] \text{sen}\left(2\theta + \frac{1}{2}\phi\right) \\ &- \left[ \Delta I_o \cos\left(\frac{1}{2}\theta\right) \right] \text{sen}\left(2\theta + \frac{1}{2}\theta\right) \quad \therefore \phi = \theta \\ &- 0 \quad \therefore \cos\left(\frac{1}{2}\theta\right) = 0 \end{aligned} \quad (85)$$

$$I'_{L_o}(\theta, \phi) = I_o$$

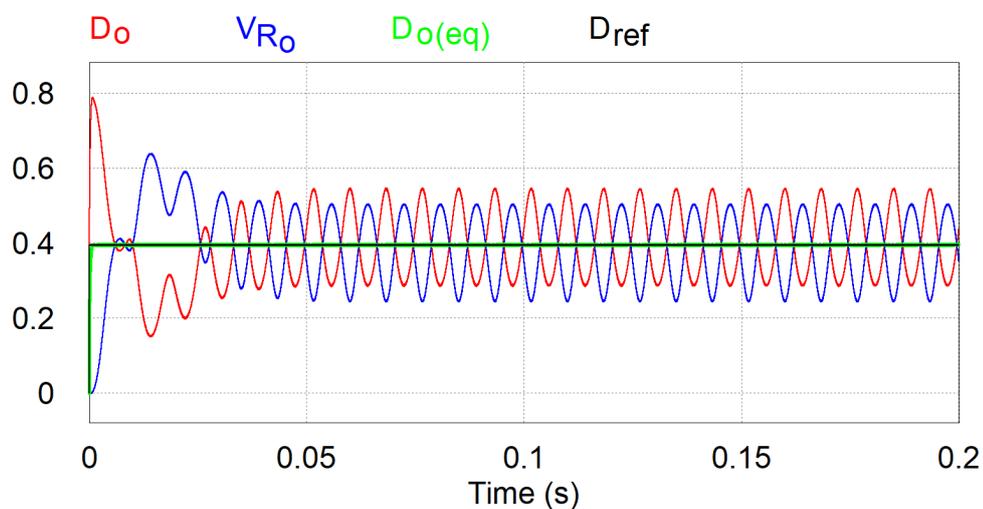
A partir do resultado apresentado pela Equação (85) mostra-se que o Princípio da Superposição de Ondas é válido para o termo ondulatório de  $I'_{L_o}(\theta)$  com  $\phi = \theta$ , de modo que o termo é cancelado e, portanto,  $I'_{L_o} = I_o$ . Como consequência de  $I'_{L_o} = I_o$ ,  $V'_{R_o}$  encerra em  $V_o$ , como pode ser averiguado na Equação (86), portanto  $D_o \equiv V_{R_o} \equiv D_{ref} \equiv V_o$ , o que implica na confirmação dos limites (80) e (81).

$$\begin{aligned} V'_{R_o}(\theta, \phi) &= R_o \cdot \left[ I_o - \frac{\Delta I_o}{2} \text{sen}(2\theta + \phi) \right] \quad \therefore \phi = \theta \\ V'_{R_o}(\theta, \phi) &= R_o \cdot I_o \\ V'_{R_o}(\theta, \phi) &= V_o \end{aligned} \quad (86)$$

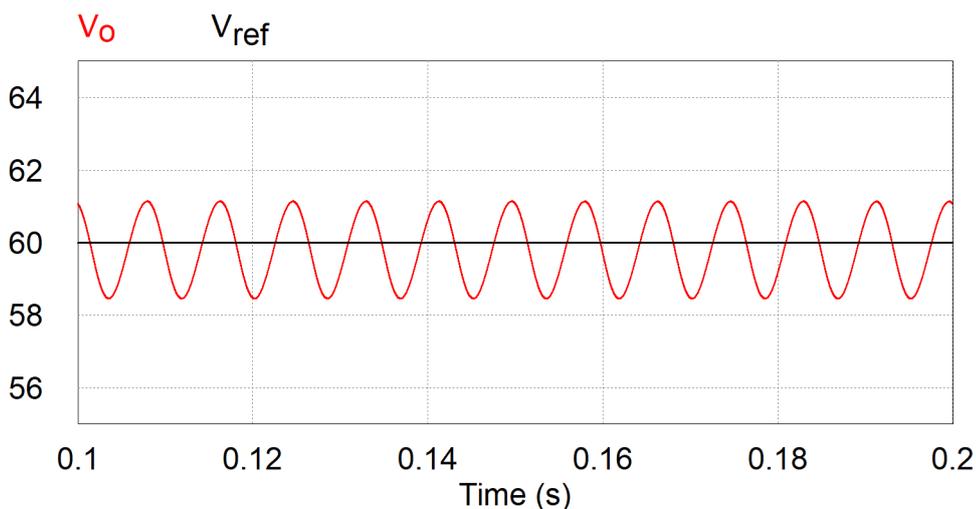
5. De sorte que,  $D_o$  assumindo o comportamento ditado pela Equação (83), porquanto  $V_{R_o}$  reflete naturalmente o comportamento da Equação (82), mostra-se pelo Princípio da Superposição de Ondas, que o limite dado pela Equação (77) é verdadeiro e confirma a aproximação,  $\epsilon$ , de acordo com a Equação (71) para o neurônio aditivo.

A julgar pelo limite apontado na Equação (77), os gráficos ilustrados na Figura 79, indicam que o ANNC aproxima  $D_o$  de  $V'_{R_o}$  sob o prisma de  $I'_{L_o}$  para  $\phi = \theta$ . Sendo assim os gráficos validam a Equação (86) pois descrevem o comportamento esperado de  $D_o$  para que  $D_{o(eq)} \equiv D_{ref}$ . Dessa forma pode-se afirmar, com base nos resultados, que o ANNC representa um aproximador de funções e que a metodologia proposta para o controle do Buck PFC é válida.

Figura 79 – Comportamento de  $D_o$  e  $V_{R_o}$  frente a aproximação de  $D_{o(eq)}$  para  $D_{ref}$ , o que produz a aproximação de  $V_o$  em relação a  $V_{ref}$ .  $V_{R_o}$  encontra-se normalizado no intervalo [0 1].



(a) ANNC aproxima  $D_o$  de  $V_{R_o}'$ , bem como  $D$  de  $D_{ref}$  e ajusta os *Offsets* de  $D_o$  e  $V_{R_o}$  para  $D_{ref}$

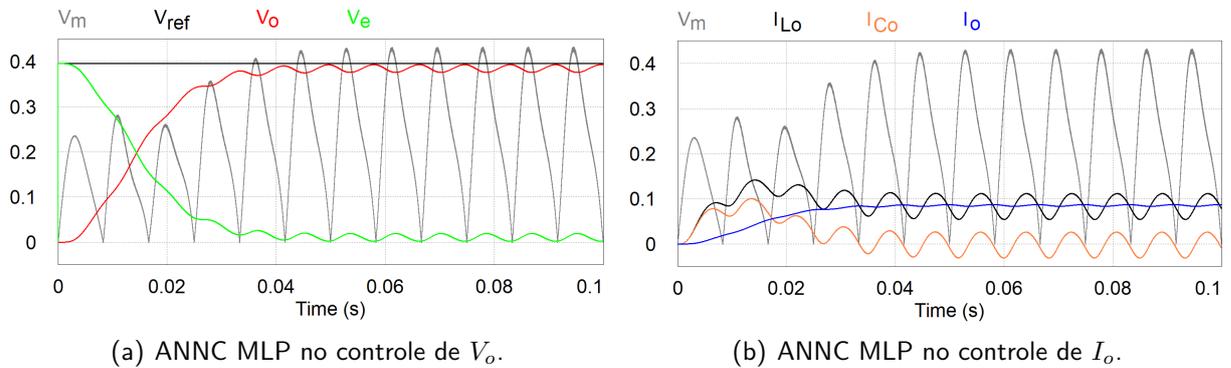


(b) ANNC aproxima  $V_o$  de  $V_{ref}$ , como esperado.  $\Delta V_o$  encontra-se dentro dos limites do projeto.  $V_o$  e  $V_{ref}$  possuem a mesma magnitude por isso ocultou-se o eixo de  $V_{ref}$ .

Fonte: Autoria própria - Simulador PSIM.

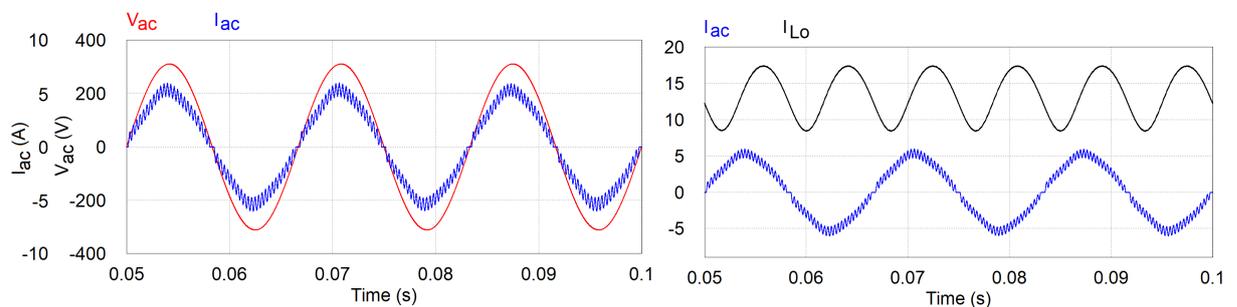
## APÊNDICE B – RESULTADOS DO BUCK PFC PARA A RNA MLP

Figura 80 – Cenário da Figura: 57. ANNC no controle de  $V_o$  e  $I_o$  a partir do ajuste na variação de  $V_m$ . Resposta para uma carga de 800 W com indutor de saída de 18 mH.  $V_{ref}$ ,  $V_o$ ,  $I_{Lo}$ ,  $V_e$ ,  $I_{Co}$  e  $I_o$  encontram-se normalizados no intervalo [0 1].



Fonte: Autoria própria - Simulador PSIM.

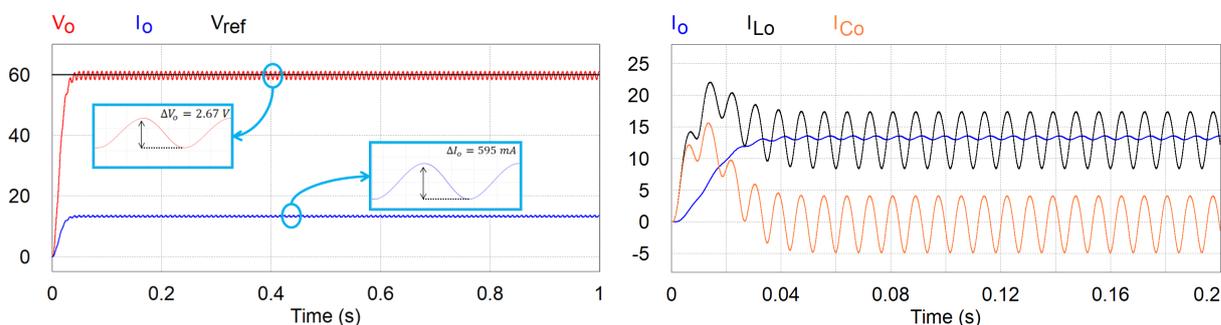
Figura 81 – Cenário da Figura 58. Gráfico da tensão e da corrente de entrada,  $V_{ac}$  e  $I_{ac}$  para um  $FP = 0,99277$ . Resposta para uma carga de 800 W com indutor de saída de 18 mH.



(a) ANNC MLP no controle de  $I_{ac}$ , responsável por um  $FP = 0,99277$ .

(b) Valor absoluto de  $I_{Lo}$  acima de  $I_{ac}$  de pico para ANNC MLP.

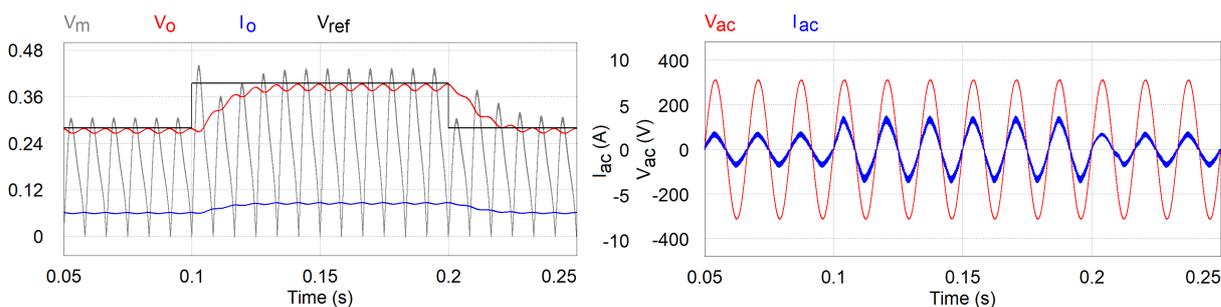
Figura 82 – Cenário da Figura 59. Gráficos da tensão e da corrente de saída,  $V_o$  e  $I_o$ . Resposta para uma carga de 800 W com indutor de saída de 18 mH.



(a) Análise de  $V_o$ ,  $I_o$  e  $V_{ref}$  para o intervalo de 0 a 1 s para o ANNC MLP. (b) Análise de  $I_o$ ,  $I_{Lo}$  e  $I_{Co}$  para o intervalo de 0 a 200 ms para o ANNC MLP.

Fonte: Autoria própria - Simulador PSIM.

Figura 83 – Cenário da Figura 60. Resposta do ANNC ao degrau em  $V_{ref}$ , com indutor de saída de 18 mH.  $V_o$  e  $I_o$  encontram-se normalizados no intervalo [0 1].

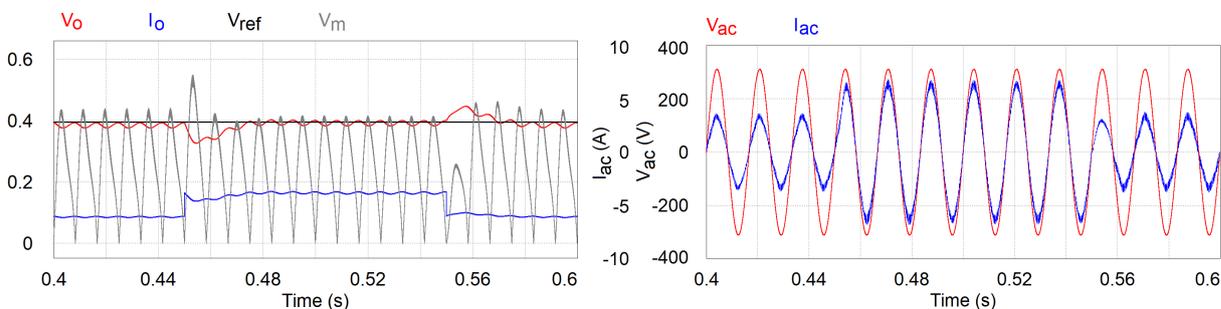


(a) ANNC MLP sob um degrau em  $V_{ref}$ .

(b) ANNC MLP corrigindo  $I_{ac}$ .

Fonte: Autoria própria - Simulador PSIM.

Figura 84 – Cenário da Figura 61. Atualização de  $V_m$  frente a variação em  $P_o$  alternando entre 800 e 1500 watts com indutor de saída de 18 mH.  $V_{ref}$ ,  $V_o$  e  $I_o$  encontram-se normalizados no intervalo [0 1].



(a) ANNC MLP corrigindo  $V_m$  para manter estável  $V_o$  frente ao aumento de  $I_o$ . (b) ANNC MLP corrigindo  $V_m$  para manter a forma de  $I_{ac}$  e o FP próximo da unidade.

Fonte: Autoria própria - Simulador PSIM.

## APÊNDICE C – CÓDIGO FONTE DAS RNAS ASSOCIADAS AO ANNC

O algoritmo trata dos passos gerais que servem como base para a implementação do ANNC. No entanto, o modelo pode não ser suficiente para que a proposta seja replicada e testada por outros pesquisadores. Diante dessa premissa optou-se por encerrar neste capítulo a codificação em linguagem C das partes mais relevantes do ANNC. Considerando que é extremamente trivial acrescentar a camada oculta ao ANNC, como consta do ANNC Multicamada, o exemplo a seguir trata apenas da arquitetura Monocamada. Dessa forma segue os componentes principais da codificação do ANNC:

### 1. Configuração inicial:

```

1  /*****
2  Instituição: UFSC
3  Programa: Mestrado - PPGESE
4  Data: 09/06/2021
5  Autor: Carlúcio Silva
6  Projeto: ANNC - Adaptative Neural Network Controller
7  Eletrônica: Retificador/Conversor Buck Monofásico
8  Arquivo: ANNC_Monocamada_ELU_Dissertacao.txt
9  Algoritmo: Monocamada + Backpropagation + RMSprop
10 Arquitetura: Input: 6, output: 1
11 Função de ativação: ELU
12 Função de custo: SME - Square Mean Error
13
14 [1] Descrição de funcionamento:
15     ANNC para controle de um retificador Buck. Na medida
16     que o retificador inicia sua operação a rede neural
17     começa a ser treinada de modo a corrigir os pesos com
18     o objetivo de adequar o duty cycle do PWM para que se
19     obtenha  $V_o = V_{ref}$  com  $FP = 1$ .
20
21 [2] Dados de entrada do ANNC:
22      $V_o = x_1;$ 
23      $V_{ac} = x_2;$ 
24      $I_o = x_3;$ 
25      $I_{Lo} = x_4;$ 
26      $I_{ac} = x_5;$ 
27      $V_{ref} = x_6;$ 
28
29 [3] Dados do ANNC:
30      $V_o$ : Tensão de saída do conversor
31      $V_{ac}$ : Tensão de entrada do conversor

```

```
32     Io:     Corrente média sobre Ro
33     I_Lo:   Corrente sobre Lo
34     Iac:    Corrente de entrada
35
36     Entradas da ANN:
37     input_layer[0] = Vac;    // Vac
38     input_layer[1] = Iac;    // Iac
39     input_layer[2] = Io;     // Io
40     input_layer[3] = I_Lo;   // I_Lo
41     input_layer[4] = 1.0;    // Entrada relativa ao bias
42
43 [4] Configuração:
44     Vref: 60 volts
45     Time step: 1 us
46     Total time: 1000 ms
47
48 [5] Resultado:
49     Vo: 59.58 V
50     Io: 13.41 A
51     Ro: 4.5 Ohm
52 *****/
53 //BIBLIOTECAS:
54 #include <math.h>
55
56 //CONSTANTES DE CONTROLE:
57 #define TRUE 1
58 #define FALSE 0
59 #define ELU
60
61 //CONSTANTES ANNC:
62 #define neta_df 1.0e-3    //Taxa de aprendizado inicial
63 #define beta 0.9         //Parâmetro beta demais pesos
64 #define beta2 0.999     //Parâmetro beta para o bias
65 #define epsilon 1.0e-8  //Passos de atualização de neta
66 #define threshold 1.0e-3 //Limiar de aprendizado
67 #ifndef ELU
68     #define adj_elu 1.0    //Inclinação da ELU
69 #else
70     #define adj_sigmoid 1.0 //Inclinação da Sigmoid
71 #endif
72 #define input 5          //Número de entradas da rede
```

## 2. Função de ativação:

```
1 #ifdef ELU
2 //Função de ativação: ELU
3 double activateFunction(double Do_linha){
4     if(Do_linha > 0)
5         return Do_linha;
6     else
7         return ( adj_elu * (exp(Do_linha) - 1) );
8 }
9 //Derivada da função de ativação: ELU
10 double dt_activationFunction(double Do_linha){
11     if(Do_linha > 0)
12         return 1.0;
13     else
14         return ( activateFunction(Do_linha) + adj_elu);
15 }
16 #else
17 //Função de ativação: Sigmoid
18 double activateFunction(double Do_linha){
19     return (1.0 / (1.0 + exp(-adj_sigmoid * Do_linha)));
20 }
21 //Derivada da função de ativação: Sigmoid
22 double dt_activationFunction(double Do_linha){
23     double network;
24     network = activateFunction(Do_linha);
25     return (adj_sigmoid * network * (1.0 - network));
26 }
27 #endif
```

## 3. Rotina que promove a computação para frente: Forward

```
1 void forward(void){
2
3     //Faz a computação de vk
4     for(i = 0, Do_linha = 0.0; i < input; i++){
5         Do_linha += wheighths[i] * input_layer[i];
6     }
7
8     //Faz a computação de yk: razão cíclica
9     Do = activateFunction(Do_linha);
10 }
```

## 4. Rotina que promove a computação para trás: Backward

```

1 void backward(void){
2     // Calcular o gradiente local: delta
3     delta = error * dt_activationFunction(Do_linha);
4     // RMSprop: Taxa de aprendizado dinâmica
5     mv_delta = beta * bkp_mv_delta + (1 - beta) * delta *
        delta;
6     neta = neta_df / sqrt(mv_delta + epsilon);
7     bkp_mv_delta = mv_delta;
8     // Calcular a derivada dos pesos da output layer: dE_dw_o
9     for(i = 0; i < input; i++){
10        dE_dw[i] = delta * input_layer[i];
11    }
12    //Atualiza os pesos da rede exceto o bias
13    for(i = 0; i < input - 1; i++){
14        wheighths[i] = wheighths[i] + dE_dw[i] * neta;
15    }
16    // RMSprop: Taxa de aprendizado dinâmica do bias
17    mv_delta_b = beta2 * bkp_mv_delta_b + (1 - beta2) * delta
        * delta;
18    neta_b = neta_df / sqrt(mv_delta_b + epsilon);
19    bkp_mv_delta_b = mv_delta_b;
20    // Atualizar wheighths bias
21    wheighths[input - 1] = wheighths[input - 1] + dE_dw[input -
        1] * neta_b;
22 }

```

## 5. Rotina para atualização das entradas:

```

1 void readInput(void){
2     // Inicializa Vo, Vs, Io e Is
3     Vac = x2;
4     Iac = x5;
5     // Setar os limites de acordo com a concessionária de
        energia
6     Vo = normalizer(abs(x1));
7     Vs = normalizer(abs(x2));
8     Io = normalizer(abs(x3));
9     I_Lo = normalizer(abs(x4));
10    Is = normalizer(abs(x5));
11    Vref = x6;
12    // Ajustar Vref para compensar a tensão de ondulação em
        Vo
13    Vref = Vref + (Vref * 0.05) / 2.0;

```

```

14 // Inicializar razão cíclica Dref
15 Dref = Vref;
16 // Inicializar as entradas da ANN: se "squaredError <=
    threshold"
17 if(trained){
18     input_layer[0] = Vs; // Vac em módulo
19     input_layer[1] = Is; // Iac em módulo
20     input_layer[2] = Io; // Io
21     input_layer[3] = I_Lo; // I_Lo
22     input_layer[4] = 1.0; // Entrada fixa relativa ao
        bias
23 }
24 // Tensão de erro: Ve = Vref-Vo
25 Ve = Vref - Vo;
26 // Ajustar Io e Vo para evitar divisão por zero
27 if(Vo && Io) {Io_temp = Io;} else {Vo = 0.0; Io_temp =
    1.0;}
28 // Tensão sobre Ro (Vo/Io) dado I_Lo
29 V_Ro = ((Vo / Io_temp) * I_Lo);
30 }

```

## 6. Rotina para o controle do fluxo de processamento do algoritmo:

```

1 void processANN(void){
2     // Faz a leitura das entradas do IANNC
3     readInput();
4     // Chamar a função de processamento para frente
5     forward();
6     // Razão cíclica equivalente
7     Do_eq = (V_Ro + Do) / 2.0;
8     // Erro
9     error = Dref - Do_eq;
10    //Calcular o SME: Square Mean Error
11    squaredError = smeFunction();
12    // Setup para a atualização das entradas
13    if(squaredError >= threshold)trained = FALSE;
14    else trained = TRUE;
15    // Sinal modulante: Vm
16    Vm = (Do * Vs);
17    //Executa a computação para traz
18    backward();
19 }

```

## APÊNDICE D – PROJETO FÍSICO DOS INDUTORES

### D.1 CÁLCULO DO INDUTOR DE ENTRADA $L_f$

O definição física do indutor  $L_f$  utilizado no Buck PFC desenvolvido no Capítulo 3, de acordo com Fabiana Pottker de Souza *et al.* (2000) o modelo construtivo foi baseado em Martignoni (2012), onde por este circula a corrente de entrada com sua componente principal bem como as harmônicas provocadas pela comutação da chave  $S$ , será a base dos cálculos a seguir.

A especificação do indutor de entrada é:

$$\begin{cases} L_f = 1.4 \text{ mH} \\ i_{S(\text{pico})} = 9,65 \text{ A} \\ f(\text{linha}) = 60 \text{ Hz} \end{cases}$$

A reatância indutiva,  $X_{L_f}$ , a diferença de potencial,  $\Delta V_{L_f}$ , e a potência aparente do indutor podem ser evidenciados nas Equações (87), (88) e (89).

$$X_{L_f} = 2\pi f(\text{linha})L_f = 2 \cdot \pi \cdot 60 \cdot 1,410^{-3} = 0,53 \Omega \quad (87)$$

$$\Delta V_{L_f} = X_{L_f} \frac{i_{S(\text{pico})}}{\sqrt{2}} = 0,53 \cdot \frac{9,65}{\sqrt{2}} = 3,62 \text{ V} \quad (88)$$

$$W_{L_f} = \Delta V_{L_f} i_{S(\text{pico})} = 3,62 \cdot 9,65 = 35 \text{ VA} \quad (89)$$

Portanto calcula-se as seções magnéticas e geométricas de  $L_f$  pelas Equações (90) e (91).

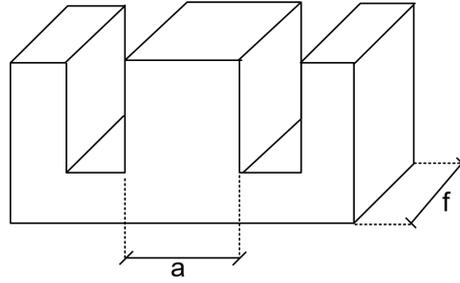
$$W_{2L_f} = \frac{W_{L_f}}{2} = \frac{35}{2} = 17,5 \text{ VA}$$

$$S_{mL_f} = 7,5 \sqrt{\frac{W_{2L_f}}{f(\text{linha})}} = 7,5 \cdot \sqrt{\frac{17,5}{60}} = 4,05 \text{ cm}^2 \quad (90)$$

$$S_{gL_f} = 1,1 S_{mL_f} = 1,1 \cdot 4,05 = 4,46 \text{ cm}^2 \quad (91)$$

O núcleo de ferro silício adotado para a construção de  $L_f$  é de 2,3 cm por 2,3 cm, com o formato segundo consta na Figura 85. Para a definição do núcleo considera-se que este tenha sua seção geométrica maior que a seção encontrada pela Equação (91).

De posse da definição do núcleo, ajusta-se os valores das seções magnéticas e geométricas da lâmina,  $S^{(l)}$ , e também o número mínimo de espiras, o que pode ser evidenciado pelas Equações (92), (93), (94) e 95) para um sistema operando com  $f(\text{linha})$  de 60 Hz.

Figura 85 – Núcleo Laminado de Ferro Cilício para o  $L_f$ 

Fonte: Adaptado de (SOUZA, F. P. d. et al., 2000)

$$S_{g_{L_f}}^{(l)} = af = 2,3 \cdot 2,3 = 5,29 \text{ cm}^2 \quad (92)$$

$$S_{m_{L_f}}^{(l)} = \frac{S_{g_{L_f}}^{(l)}}{1,1} = 4,9 \text{ cm}^2 \quad (93)$$

$$Esp/vol = \frac{33,5}{S_{m_{L_f}}^{(l)}} = \frac{33,5}{4,9} = 6,837 \quad (94)$$

$$N_{(espiras)} = Esp/volt \cdot \Delta V = 6,837 \cdot 3,62 = 25 \text{ espiras} \quad (95)$$

A seção do condutor (área do cobre) é calculada por meio da Equação (96), onde  $d$  representa a densidade da corrente.

$$S_{cu(cond)} = \frac{i_{S(pico)}}{d} = \frac{9,65}{3} = 3,22 \text{ mm}^2 \quad (96)$$

O fio utilizado é o 22 AWG com doze enrolamentos em paralelo, o qual possui seção de  $0,33 \text{ mm}^2$ , resultando numa seção de cobre total de  $0,99 \text{ cm}^2$  calculada pela Equação (97). A seção da janela pode ser encontrada por meio da Equação (98).

$$S_{cu} = N_{(espiras)} \cdot 12 \cdot 0,0033 = 0,99 \text{ cm}^2 \quad (97)$$

$$S_j = af \cdot 0,75 = 2,3^2 \cdot 0,75 = 3,9675 \text{ cm}^2 \quad (98)$$

A possibilidade de execução é informada através da relação entre  $S_j$  e  $S_{cu}$  como consta na Equação (99), e que deve ser maior que 3.

$$P_{(exec)} = \frac{S_j}{S_{cu}} = \frac{3,9675}{0,99} = 4,0075 > 3 \quad (99)$$

Para encontrar o valor do entreferro em  $cm$  deve-se considerar os passos seguintes:

1. Pela Equação (100) determina-se o comprimento do circuito magnético do ferro,  $I_F$ .

$$I_F = 5,6 \cdot a = 5,6 \cdot 2,3 = 12,88 \text{ cm} \quad (100)$$

2. A força magnetomotriz máxima,  $f_{m(máx)}$ , que atua no núcleo é encontrada de acordo com a Equação (101).

$$f_{m(máx)} = N_{(espiras)} i_{S(pico)} \sqrt{2} = 25 \cdot 9,65 \cdot \sqrt{2} = 342 \quad (101)$$

3. A magnetização do núcleo é dependente das ampère-espiras máximas,  $A_{eF(máx)}$ , que está em função de  $I_F$  e pode ser encontrada segundo a Equação (102).

$$A_{eF(máx)} = 5,6 \cdot I_F = 5,6 \cdot 12,88 = 72,128 \quad (102)$$

4. Subtraindo  $A_{eF(máx)}$  de  $f_{m(máx)}$  obtém-se as ampère-espiras máximas destinadas para o cálculo do entreferro,  $A_{eE(máx)}$ , o qual pode ser calculado por meio da Equação (103).

$$A_{eE(máx)} = f_{m(máx)} - A_{eF(máx)} = 342 - 72,128 = 269,92 \quad (103)$$

5. Considerando que cada circuito magnético do núcleo possui dois entreferros, o comprimento do entreferro do núcleo pode ser encontrado pela Equação (104).

$$l_g = \frac{269,92}{0,8 \cdot 11300 \cdot 2} = 0,015 \text{ cm} \quad (104)$$

## D.2 CÁLCULO DO INDUTOR DE SAÍDA $L_o$

O definição física do indutor  $L_o$ , onde circula a corrente média de saída com ondulação de 120 Hz, tem como referência Fabiana Pottker de Souza *et al.* (2000), F Pottker Souza e Barbi (1999) e MC LYMAN (1998).

A especificação do indutor de saída é:

$$\begin{cases} L_f = 18 \text{ mH} \\ I_o = 25 \text{ A} \\ \Delta I_o = 17,9 \text{ A} \end{cases}$$

A corrente  $I_{L_o(pico)}$  é encontrada pela Equação (105).

$$I_{L_o(pico)} = I_o + \frac{\Delta I_o}{2} = 25 + \frac{17,9}{2} = 33,95 \text{ A} \quad (105)$$

A anergia é calculada em seguida pela Equação (106).

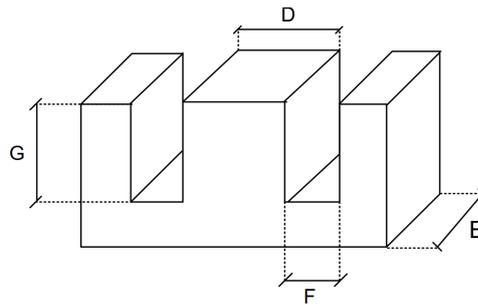
$$Energia_{(L_o)} = \frac{LI_{L_o(pico)}^2}{2} = \frac{18 \cdot 10^{-3} \cdot 33,95^2}{2} = 10,373 \text{ J} \quad (106)$$

O produto das áreas é calculado de acordo com MC LYMAN (1998) pela Equação (107). O fator de ocupação da janela,  $k_u$ , considera-se 0,75, a densidade de fluxo 1,4 T, a constante  $k_j$  adota-se 534 como consta na Tabela 5-5 de MC LYMAN (1998).

$$A_p = = \frac{2 \cdot Energia_{(L_o)} \cdot 10^4}{B_k \cdot K_u \cdot K_j} = \frac{2 \cdot 10,373 \cdot 10^4}{1,4 \cdot 0,75 \cdot 534} = 370 \text{ cm}^4 \quad (107)$$

O núcleo de ferro silício selecionado, Figura 86, possui as seguintes dimensões:  $D = 5 \text{ cm}$ ,  $E = 8 \text{ cm}$ ,  $F = 2,5 \text{ cm}$  e  $G = 7,6 \text{ cm}$ . O recálculo das áreas do núcleo,  $A_p^{(l)}$ , de acordo com lâmina escolhida, pode ser acompanhado pelas Equações (108), (109) e (110).

Figura 86 – Núcleo Laminado de Ferro Cilício para o  $L_o$



Fonte: Adaptado de (SOUZA, F. P. d. et al., 2000)

$$A_c = DE = 5 \cdot 8 = 40 \text{ cm}^2 \quad (108)$$

$$W_a = GF = 7,6 \cdot 2,5 = 19 \text{ cm}^2 \quad (109)$$

$$A_p^{(l)} = A_c \cdot W_a = 40 \cdot 19 = 760 \text{ cm}^4 \quad (110)$$

A densidade de corrente é calculada pela Equação (111) com o uso das constantes  $K_j$  e  $y$  (SOUZA, F. P. d. et al., 2000).

$$J = K_j A_p^{(l)y} = 534 \cdot 760^{-0,12} = 240,9 \text{ A/cm}^2 \quad (111)$$

A seção do condutor é encontrada pela Equação (112) segundo a densidade da corrente da lâmina escolhida para o núcleo.

$$S_{cu} = \frac{I_{L_o(pico)}}{J} = \frac{33,95}{240,9} = 0,1409 \text{ cm}^2 \quad (112)$$

Utilizou-se 10 fios em paralelo 16 AWG ( $S_{cu} = 13,1 \cdot 10^{-3} \text{ cm}^2$ ,  $S_{cu(\text{isolado})} = 13,58 \cdot 10^{-3} \text{ cm}^2$ ), resultando na seção total do condutor apontada pelas Equações (113) e (114).

$$S_{cu(\text{total})} = 10 \cdot 13,1 \cdot 10^{-3} = 0,131 \text{ cm}^2 \quad (113)$$

$$S_{cu(\text{isolado})(\text{total})} = 10 \cdot 13,58 \cdot 10^{-3} = 0,1358 \text{ cm}^2 \quad (114)$$

A área efetiva da janela,  $W_{a(\text{efetiva})}$ , é encontrada segundo  $W_a$ , considerando a constante  $S_3 = 0,75$ , a partir da Equação (115) (SOUZA, F. P. d. *et al.*, 2000).

$$W_{a(\text{efetiva})} = W_a S_3 = 13,6 \cdot 0,75 = 10,2 \text{ cm}^2 \quad (115)$$

De posse de  $W_{a(\text{efetiva})}$  e  $S_{cu(\text{isolado})(\text{total})}$  calcula-se por meio da Equação (116) o número mínimo de espiras de  $L_o$ . De acordo com Fabiana Pottker de Souza *et al.* (2000) o valor típico para  $S_2$  é 0,6.

$$N_{(\text{espiras})} = \frac{W_{a(\text{efetiva})} S_2}{S_{cu(\text{isolado})(\text{total})}} = \frac{10,2 \cdot 0,6}{0,1358} = 45 \text{ espiras} \quad (116)$$

O entreferro é calculado de acordo com a Equação (117).

$$l_g = \frac{0,4 \cdot \pi \cdot N_{(\text{espiras})}^2 \cdot A_c \cdot 10^{-8}}{L_o} = \frac{0,4 \cdot \pi \cdot 45^2 \cdot 40 \cdot 10^{-8}}{18 \cdot 10^{-3}} = 6,36 \cdot 10^{-2} \text{ cm} \quad (117)$$

A partir do valor do entreferro recalcula-se o número mínimo de espiras para  $L_o$  por meio das Equações (118) e (119).

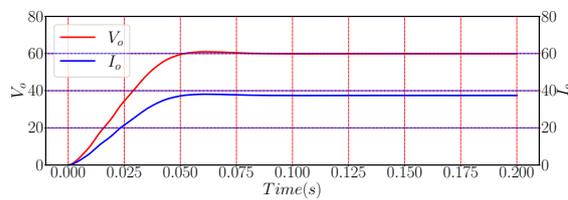
$$F = 1 + \frac{l_g}{\sqrt{A_c}} \ln \left( \frac{2 \cdot G}{l_g} \right) = 1 + \frac{6,36 \cdot 10^{-2}}{\sqrt{40}} \ln \left( \frac{2 \cdot 7,6}{6,36 \cdot 10^{-2}} \right) = 1,055 \quad (118)$$

$$N_{(\text{espiras})} = \left( \frac{l_g \cdot L_o}{0,4 \cdot \pi \cdot A_c \cdot F \cdot 10^{-8}} \right)^{\frac{1}{2}} = \left( \frac{6,36 \cdot 10^{-2} \cdot 18 \cdot 10^{-3}}{0,4 \cdot \pi \cdot 40 \cdot 1,055 \cdot 10^{-8}} \right)^{\frac{1}{2}} = 33,77 \text{ espiras} \quad (119)$$

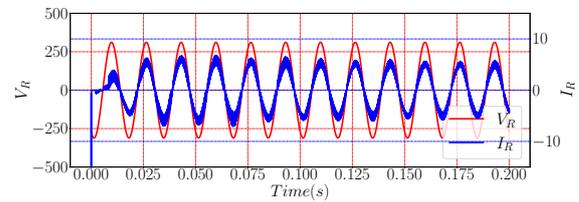
## APÊNDICE E – BUCK PFC TRIFÁSICO

A Figura 87 apresenta os resultados numéricos para o conversor da Figura 4 apresentado na Seção 1.1. Pode-se observar no âmbito da Figura 87, a partir do terceiro ciclo da rede, a correção do sinal das correntes de entrada, a forma do sinal após o distúrbio da inicialização aponta para um fator de potência próximo da unidade, o que é possível avaliar nas Figuras 87(b), 87(c) e 87(d). De acordo com a Figura 87(a) o tempo de subida é cerca de três ciclos da rede, que o *overshoot* é praticamente inexistente e o tempo de estabilização é pelo menos cinco ciclos da rede. A priori tais indicadores favorecem à continuidade do estudo do ANNC para os retificadores trifásicos.

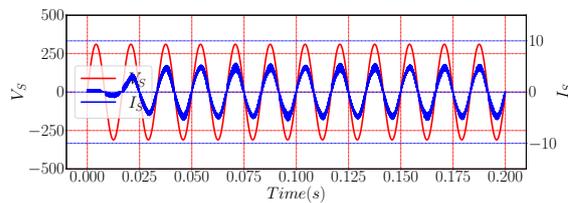
Figura 87 – Desempenho do ANNC para o Buck PFC trifásico.



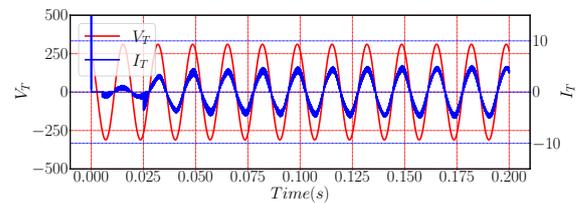
(a) Tensão e Corrente de Saída.



(b) Fase R, FP igual a 0,993.



(c) Fase S, FP igual a 0,996.



(d) Fase T, FP igual a 0,994.

Fonte: Autoria própria - Simulador PSIM.