

# Um Método Inteligente para a Correção da Forma de Onda Secundária de Transformadores de Corrente de Proteção

Bruno dos Santos Saraiva Silva. Ricardo Caneloi do Santos\*. Edmarcio Antônio Belati

*Universidade Federal d ABC, Santo André, SP, Brasil  
Centro de Engenharia, Modelagem e Ciências Sociais Aplicadas  
(e-mail: ricardo.santos@ufabc.edu.br)*

---

**Abstract:** One of the most important equipments used in protection systems is the current transformer (CT). However, the CTs have physical characteristics that makes them susceptible to saturation, causing the secondary current's waveform to be distorted. Due to that distortion the relay may fail, not generating the trip signal when a fault takes place in the power system. Therefore, this paper proposes the use of Artificial Neural Networks (ANNs) to correct the distorted secondary current's waveform provided by saturated CTs. The results clearly show that a highly distorted current waveform can be fully reconstructed by ANNs, providing the protection relays a trustworthy signal for its correct decision making process.

**Resumo:** Um dos equipamentos mais importantes presentes no sistema de proteção é o Transformador de Corrente (TC). No entanto, tal equipamento possui características físicas que o torna susceptível à saturação, resultando na distorção da sua forma de onda secundária. Diante desta distorção o relé de proteção pode falhar, deixando de gerar o sinal de *trip* diante de situações de falta no sistema elétrico. Neste sentido, este trabalho propõe o uso de Redes Neurais Artificiais (RNAs) para corrigir a forma de onda secundária distorcida proveniente de um TC saturado. Os resultados mostram claramente que uma forma de onda altamente distorcida pode ser totalmente reconstruída pela RNA, fornecendo aos relés de proteção um sinal confiável para a correta tomada de decisão.

**Keywords:** Current transformer; CT saturation; Artificial Neural Networks; Power System Protection; Digital Relay.

**Palavras-chaves:** Transformador de Corrente; Saturação de TC; Redes Neurais Artificiais, Proteção de Sistemas Elétricos, Relé Digital.

---

## 1. INTRODUÇÃO

Um dos elementos mais importantes dos esquemas de proteção empregados nos Sistemas Elétricos de Potência (SEP) é o Transformador de Corrente (TC), pois este compatibiliza as elevadas correntes que fluem nas linhas de transmissão com o nível de corrente requerido pelos relés digitais (5A ou 1A). Nesse sentido, o TC fornece ao relé digital uma réplica fiel, em escala reduzida, da corrente que flui na linha de transmissão. No entanto, devido as suas características construtivas, diante de elevadas correntes de falta, os TCs podem entrar em estado de saturação, distorcendo a corrente secundária entregue ao relé digital. Como resultado, o dispositivo de proteção pode tomar uma decisão equivocada, deixando, por exemplo, de emitir um sinal de *trip* diante de uma situação de falta.

Para lidar com a saturação dos TCs empregados em esquemas de proteção, muitos trabalhos propondo algoritmos (determinísticos ou inteligentes) para a detecção da saturação do TC e correção da sua forma de onda secundária são apresentados na literatura. Em Kang (1997) os autores apresentam um algoritmo para a compensação da corrente

secundária do TC saturado, utilizando sua curva de magnetização. Apesar dos bons resultados obtidos, esse método pode impor significativo atraso ao sinal corrigido resultante. Em Yu (1999) os autores criam um método baseado em RNAs capaz de detectar a saturação do TC e obter a função de transferência de TCs toroidais com núcleo de ferro (tipicamente utilizados em sistemas de proteção). Esse método foi testado em *hardware* e apresentou resultados promissores. Em Ozgonenel (2013) o autor desenvolve uma técnica para a detecção da saturação do TC por meio da aproximação da permeabilidade do seu núcleo (empregando a técnica de Frölich), o que permite o cálculo da corrente de magnetização. Esse método é bastante dependente da taxa de amostragem utilizada. Em Haghjoo (2016) foram discutidos dois métodos para a correção da forma de onda secundária de TCs de proteção, avaliando os desempenhos dos mesmos na presença de ruídos e alterações na topologia da rede elétrica. Os métodos mostraram-se promissores, porém dependendo da condição de falta, os erros obtidos podem ser altos.

Dada a importância de fornecer ao relé de proteção uma corrente que represente fielmente a corrente de falta, este trabalho apresenta um algoritmo baseado em RNAs para a

correção da forma de onda distorcida proveniente do secundário de TCs saturados. Diferentemente de outros trabalhos, o algoritmo apresentado possui baixa carga computacional (pois utiliza uma baixa taxa de amostragem), não requer nenhum pré-processamento e compara a implementação das RNAs em Matlab e Python.

## 2. SATURAÇÃO DO TC DE PROTEÇÃO

A saturação de um TC ocorre devido às suas características construtivas e condição de funcionamento. A Figura 1 ilustra uma curva típica de campo magnético por densidade de fluxo. O núcleo de um TC, tipicamente de ferro, é composto por dipolos magnéticos. Quando o TC não é percorrido por corrente elétrica, tais dipolos estão dispostos de forma aleatória, sem uma orientação específica. Na medida que a quantidade de corrente que passa pelo TC aumenta, mais forte se torna o campo magnético e maior é o alinhamento dos dipolos magnéticos. Depois de certo ponto, quando praticamente todos os dipolos magnéticos já encontram-se alinhados, a densidade de fluxo já não mais aumenta e o TC entra em saturação, conforme pode ser observado no ponto *a* da Figura 1. Cada TC possui uma curva diferente, que reflete sua capacidade de suportar grandes correntes (grandes campos magnéticos) sem entrar em estado de saturação.

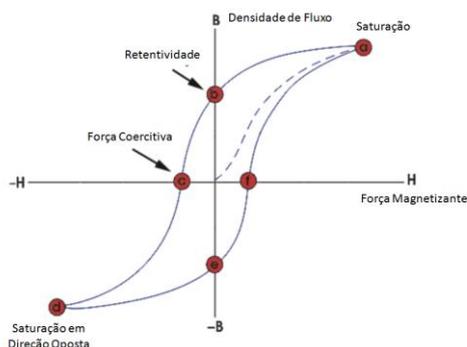


Figura 1 - Curva de histerese.

([www.nde-ed.org/EducationResources/CommunityCollege/MagParticle/Physics/HysteresisLoop.htm](http://www.nde-ed.org/EducationResources/CommunityCollege/MagParticle/Physics/HysteresisLoop.htm))

A maior parte dos dispositivos de proteção tomam decisões baseadas no valor RMS da corrente de falta. Se um sinal de corrente, transmitido pelo TC ao equipamento de proteção, encontra-se distorcido pela saturação do TC, o valor RMS calculado será substancialmente menor que a corrente de falta real, afetando negativamente o desempenho da proteção. Para ilustrar tal efeito, a Figura 2 ilustra a corrente RMS calculada por um relé diante de uma forma de onda secundária não saturada (condição desejada) e uma forma de onda secundária saturada. Como pode ser observado existe um atraso significativo até a forma de onda saturada atingir o valor RMS esperado (correto).

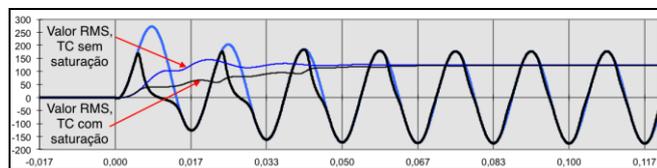


Figura 2 - Efeito da saturação no cálculo do valor RMS. (Fonte: Autor)

## 3. REDES NEURAIS ARTIFICIAIS

As Redes Neurais Artificiais são provavelmente um dos campos mais promissores dentro de *Machine Learning*, pois trata-se de uma ferramenta robusta, capaz de aprender determinadas tarefas como classificação, predição, *clustering*, regressão, entre outros. Tais redes podem ter um número bastante variado de camadas ocultas, sendo que quanto maior o número de camadas ocultas, maior será sua capacidade de representação de regiões complexas (Aggarwal, 2018). A título de exemplo, a Figura 3 ilustra uma RNA com quatro camadas, sendo uma de entrada, uma de saída e duas camadas ocultas.

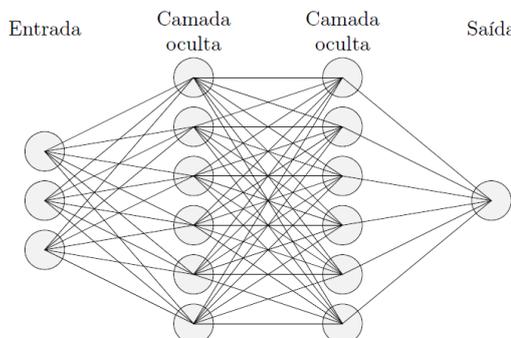


Figura 3 - Exemplo de RNA com 4 camadas. (Fonte: Autor)

Para que a RNA execute uma tarefa de interesse, esta deve ser submetida a um processo de treinamento, que consta, no caso de treinamento supervisionado, na sucessiva apresentação de pares de vetores entrada/saída conhecidos. Por meio deste processo a RNA ajusta seus pesos para aprender a função de interesse. Esse processo é ilustrado na Figura 4. Uma vez treinada adequadamente, a RNA estará apta para responder corretamente para novos sinais de entrada, ou seja, sinais que não constavam no seu processo de treinamento. Essa característica é denominada de capacidade de generalização da RNA.

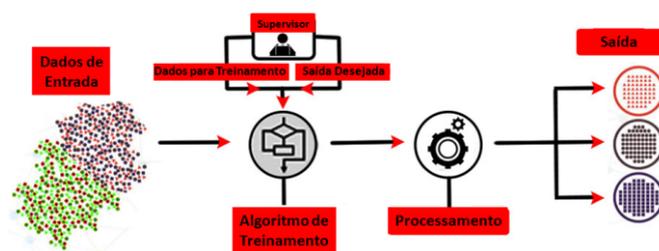


Figura 4 - Treinamento supervisionado (<https://www.datavedas.com/supervised-models/>)

### 3.1 Ambientes Computacionais para o Desenvolvimento das RNAs

Para treinar e testar as RNAs dois diferentes ambientes computacionais são utilizados, permitindo comparar o desempenho das RNAs implementadas em softwares diferentes. São eles: a) o Matlab, de grande aceitação na indústria e na academia; b) o Keras, API do *TensorFlow*, que vem ganhando crescente visibilidade na indústria e entre pesquisadores (Loy, 2019).

Para o desenvolvimento em Matlab usa-se o *Neural Network Toolbox*, que é uma ferramenta composta por modelos pré-definidos, interface gráfica e opções de visualização de dados de treinamento e testes. Neste caso, toda a programação é feita de forma gráfica e intuitiva, permitindo a importação e exportação de dados para o *Workspace*. Já o (Keras) *TensorFlow* é uma biblioteca *open source* voltada a computação numérica de alta performance. Esta ferramenta possui uma arquitetura flexível que permite o desenvolvimento de soluções em *Machine Learning* aplicável a CPUs, GPUs, TPUs - isso em desktops e servidores dedicados. O *TensorFlow* apresenta bibliotecas para as mais variadas aplicações de *Machine Learning*, sendo uma destas bibliotecas o Keras, utilizado no presente trabalho. Com apenas algumas linhas de código (em Python) é possível construir, treinar e testar uma RNA.

### 3.2 Uso das RNAs para a Aproximação de Funções

A título de exemplo, visando justificar a opção de se utilizar RNAs para a correção da forma de onda secundária de TCs saturados, na sequência é apresentada uma aplicação de RNAs para ajuste de curvas, onde sinais distorcidos são recuperados. Tal aplicação foi desenvolvida para ilustrar, de forma direta e objetiva, a capacidade das RNAs. A Figura 5 apresenta a resposta para a RNA implementada no Matlab, enquanto a Figura 6 apresenta a resposta para a RNA implementada no Keras. As Figuras 5 e 6 revelam que um sinal altamente distorcido pode ser completamente reconstruído por meio de RNAs previamente treinadas para esse fim.



Figura 5 - Reconstrução do sinal - Matlab. (Fonte: Autor)

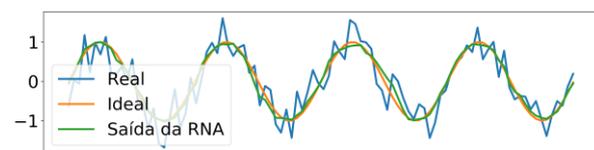


Figura 6 - Reconstrução do sinal - Keras. (Fonte: Autor)

Todos os detalhes desse exemplo de aplicação (estrutura da RNA, processo de treinamento, parâmetros utilizados e testes realizados) podem ser encontrados em Silva (2019). Claramente, por meio das Figuras 5 e 6, fica bastante evidente o potencial das RNAs para as tarefas de aproximação de funções e ajustes de curvas, justificando plenamente a opção pelo uso desta técnica, para reconstruir sinais distorcidos provenientes de TCs saturados.

## 4. GERAÇÃO DOS SINAS DE TREINAMENTO E TESTES DAS RNAs

Esta seção detalha o procedimento executado para a geração dos dados de treinamento e testes das RNAs capazes de corrigir formas de onda distorcidas provenientes do secundário de TCs saturados. A geração dos sinais para treinamentos e testes das RNAs em Matlab e Keras foi realizado por meio de um modelo matemático do TC (Tziouvaras, 2000).

O modelo matemático para TCs, baseado no trabalho publicado em Tziouvaras (2000), foi utilizado para a extração de dados de treinamento das RNAs utilizadas neste projeto. Este modelo é amplamente aceito e utilizado pela comunidade científica e por profissionais da área, fornecendo uma rápida indicação se um TC entrará em estado de saturação, bem como ilustrando como será a forma de onda secundária em caso de saturação. Para a utilização deste modelo foi ensaiado em laboratório um TC de fabricação Zilmer, permitindo o levantamento dos seus principais parâmetros para uso em ambiente computacional.

Por meio da modelagem computacional do TC, usando dados reais provenientes de ensaios laboratoriais, ondas secundárias distorcidas, relativas a diferentes correntes de falta, são geradas e visualizadas em função do tempo. Cada forma de onda é obtida com uma taxa de amostragem de 200 amostras por ciclo de 60Hz e 9 ciclos, conforme exemplificado na Figura 7. Assim, para cada valor de corrente aplicado ao TC, são extraídos dois vetores de 1800 amostras, sendo um relativo à corrente saturada e outro relativo à corrente não saturada - *targets* (saída ideal). Após a simulação de diversas situações distintas de falta, esses vetores são agrupados para formar a matriz de treinamento da RNA.

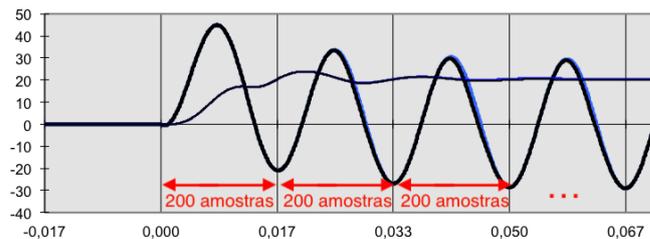


Figura 7 - Sinal gerado pelo modelo computacional do TC. (Fonte: Autor)

Para a definição da melhor topologia de RNA foram testadas dezenas de possibilidades, considerando diferentes: a) taxas de amostragem; b) tamanho de janela de dados; c) número de camadas ocultas; d) número de neurônios por camada. Depois de muitas simulações e análises, as cinco melhores RNAs foram selecionadas e listadas na Tabela 1, onde a designação da rede é expressa da seguinte forma: as primeiras quatro letras são provenientes do modelo do TC ensaiado, a quinta letra indica o ambiente de treinamento (M - Matlab) e o último número indica a posição da RNA em função da sua precisão, sendo 1 a RNA mais precisa. Ainda com relação a Tabela 1, *s* indica a taxa de amostragem (amostras por ciclo), *j* indica o número de amostras na janela de dados, *n* indica o número de neurônio em cada camada oculta e *c* o número de camadas ocultas.

Tabela 1 - Resultado do treinamento da RNA no Matlab.

RNA	Arquitetura				Erro			
	s	j	n	c	Caso 1	Caso 2	Caso 3	Acumulado
ICSHM1	12	9	25	2	0,198 %	0,060 %	0,049 %	0,308 %
ICSHM2	16	16	33	2	0,125 %	0,090 %	0,095 %	0,311 %
ICSHM3	20	15	41	2	0,321 %	0,048 %	0,041 %	0,410 %
ICSHM4	16	12	33	2	0,244 %	0,096 %	0,103 %	0,443 %
ICSHM5	12	6	25	2	0,340 %	0,089 %	0,061 %	0,490 %

Fonte: Autor

Para ilustrar a resposta da RNA com melhor desempenho (ICSHM1), esta é submetida a três diferentes condições de falta, com correntes primárias de 8580A, 16590A e 24590A, gerando três níveis distintos de saturação nos TCs.

A Figura 8 revela que a RNA é capaz de reconstruir o sinal distorcido no secundário do TC saturado, independentemente do nível de saturação do mesmo. Além da reconstrução do sinal distorcido, em função do tempo, também observa-se o resultado do cálculo do valor RMS, utilizado pela maioria dos algoritmos nos relés digitais. Nitidamente, o desempenho dos relés digitais é fortemente afetado quando o valor RMS é calculado a partir do sinal distorcido. Já quando o cálculo é realizado por meio do sinal reconstruído (saída da RNA), o valor RMS obtido é praticamente aquele esperado para a forma de onda não saturada (saída ideal).

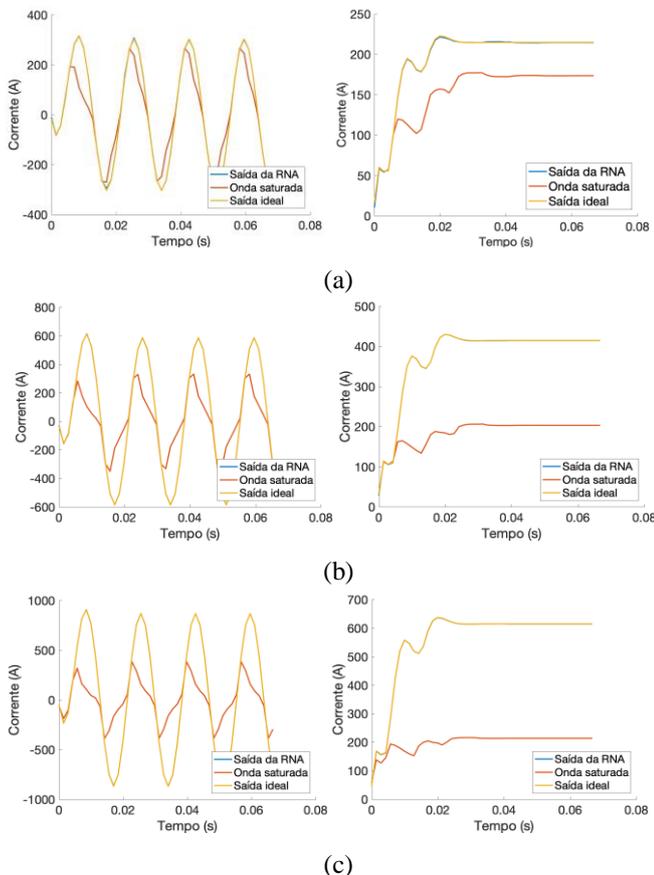


Figura 8 - Resultado da melhor RNA (Matlab) diante de: a) saturação leve; b) saturação moderada; c) saturação forte. (Fonte: Autor)

A Figura 9 revela a precisão da aproximação da resposta da RNA, comparando as formas de onda ideal e corrigida.

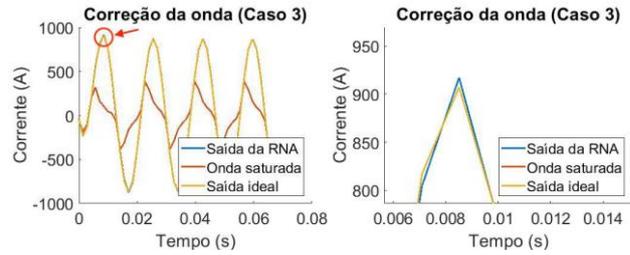


Figura 9 - Detalhe da precisão do algoritmo proposto. (Fonte: Autor)

É importante ressaltar que todos os treinamentos e testes executados anteriormente utilizaram o ambiente de computacional Matlab. Na sequência, uma avaliação semelhante à anterior será desenvolvida, porém utilizando-se o Keras. Nesse sentido, novamente, após dezenas de simulações e análises, foram selecionadas as cinco melhores RNAs na fase de treinamento. A Tabela 2 apresenta as RNAs selecionadas, onde *K* indica o *software* utilizado (*K* - Keras).

Tabela 2 - Resultado do treinamento da RNA no Keras.

RNA	Arquitetura				Erro			
	s	j	n	c	Caso 1	Caso 2	Caso 3	Acumulado
ICSHK1	12	6	25	2	0,555 %	0,675 %	0,747 %	1,977 %
ICSHK2	24	24	24	2	0,629 %	2,722 %	0,403 %	3,754 %
ICSHK3	24	18	49	2	0,984 %	0,678 %	2,252 %	3,914 %
ICSHK4	20	10	20	2	0,319 %	0,583 %	3,659 %	4,561 %
ICSHK5	20	10	41	2	0,316 %	1,405 %	3,059 %	4,780 %

Fonte: Autor

De forma análoga ao procedimento já adotado, para ilustrar a resposta da RNA com melhor desempenho (ICSHK1), esta é submetida a três diferentes condições de falta, com correntes primárias de 8580A, 16590A e 24590A, gerando três níveis distintos de saturação nos TCs. Convém ressaltar que a resposta da RNA, apesar de bastante promissora, é inferior à obtida em Matlab (o que pode ser facilmente verificado comparando-se os erros apresentados nas Tabelas 1 e 2).

A Figura 10 apresenta as respostas da RNA para três níveis distintos de saturação, gerados por correntes de falta de 8580A, 16590A e 24590A. Novamente, em função do tempo, observa-se a reconstrução dos sinais distorcidos, bem como o cálculo dos valores RMS a partir dos sinais distorcidos e reconstruídos. Apesar do desempenho inferior do Keras, com relação ao Matlab, este ainda poderia ser utilizado para manter o sistema de proteção trabalhando conforme o especificado, eliminando o efeito negativo da saturação dos TCs.

Em função de restrições do ambiente computacional utilizado, os sinais foram transferidos do Keras para o Word sem os valores dos eixos verticais (amplitude da corrente) e horizontais (tempo). No entanto, esses valores são exatamente iguais aos apresentados na Figura 8, visto que os mesmos sinais de entrada (modelo computacional do TC e níveis de corrente de falta) são utilizados. Como já discutido, trata-se de sinais senoidais com frequência de 60 Hz. Dessa forma, a informação relevante na Figura 10 é a proximidade entre o sinal desejado (ideal) e o reconstruído (saída da RNA), independentemente do nível de saturação do TC.

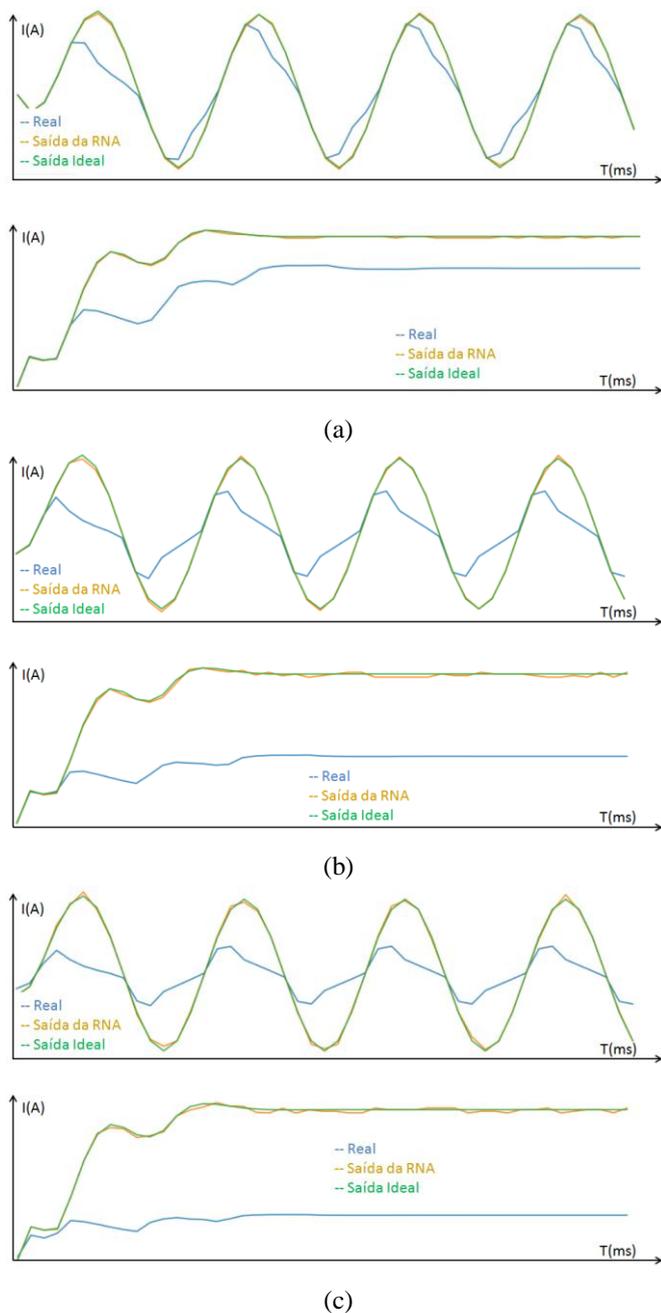


Figura 10 - Resultado da melhor RNA (Keras) diante de: a) saturação leve; b) saturação moderada; c) saturação forte. (Fonte: Autor)

É importante destacar que para todos os casos discutidos o erro foi calculado segundo a Equação (1), que considera os valores eficazes (RMS) da corrente esperada (ideal) e da corrente corrigida (saída da RNA). Os valores RMS utilizados na referida equação foram calculados por meio da TDF (Transformada Discreta de Fourier) de uma janela deslizante de um ciclo de 60 Hz.

$$E\% = \sqrt{\frac{\sum_{k=1}^N \left( i_{RMS(ideal)}^{(k)} - i_{RMS(corrigido)}^{(k)} \right)^2}{\sum_{k=1}^N \left( i_{RMS(ideal)}^{(k)} \right)^2}} \cdot 100 \quad (1)$$

## 5. CONCLUSÕES

Este trabalho teve por objetivo especificar uma RNA capaz de corrigir a forma de onda distorcida proveniente de TCs saturados. Durante o decorrer do trabalho os ambientes Matlab e Keras (*TensorFlow*) foram comparados para fins de desenvolvimento das RNAs, sendo que os melhores resultados foram obtidos no ambiente Matlab. No entanto, bons resultados também foram observados no ambiente Keras.

Além da comparação entre os ambientes Matlab e Keras, diversas topologias de RNAs foram avaliadas, bem como diferentes taxas de amostragem e tamanho de janela de dados (ver Tabelas 1 e 2). Todas as simulações e análises foram executadas considerando-se a modelagem matemática do TC para a geração dos sinais de entrada das RNAs, ou seja, formas de onda com diferentes níveis de saturação.

Constatou-se que independentemente do nível de saturação do TC, ou do ambiente computacional utilizado, as RNAs foram sempre capazes de reconstruir o sinal distorcido com precisão. Tal possibilidade garante a atuação esperada do sistema de proteção, mesmo diante de uma possível saturação severa do TC.

## REFERÊNCIAS

- Aggarwal, C. C. (2018). *Neural Networks and Deep Learning: A Textbook*, First edition, Springer (2018).
- Haghjoo, F. and Pak, M. H. (2016). Compensation of CT distorted secondary current waveform in online conditions. *IEEE Transactions on Power Delivery*, volume (31), 711–720.
- Kang, Y. C., Park, J. K., Kang, S. H., Johns, A. T., and Aggarwal, R. K. (1997). An algorithm for compensating secondary currents of current transformers. *IEEE Transactions on Power Delivery*, volume (12), 116–124.
- Loy, J. (2019). *Neural Network Projects with Python: The ultimate guide to using Python to explore the true power of neural networks through six projects*. First edition, Packt Publishing, UK.
- Ozgonenel, O. (2013). Correction of saturated current from measurement current transformer. *IET Electric Power Applications*, volume (7), 580–585.
- Silva, B. S. S. (2019). *Correção de Forma de Onda Secundária de Transformadores de Corrente de Proteção Utilizando Redes Neurais Artificiais*. Dissertação de Mestrado. UFABC, Santo André.
- Tziouvaras, D. A., et al (2000). Mathematical models for current, voltage, and coupling capacitor voltage transformers. *IEEE Trans. Power Deliv.*, vol(15), 62–72.
- Yu, D. C., Cummins, J. C., Wang, Z., Yoon, H. J., Kojovic, L. A., and Stone, D. (1999). Neural network for current transformer saturation correction. *In IEEE Transmission and Distribution Conference*, 441–446.