

MODELAGEM DE LÂMPADA FLUORESCENTE COMPACTA PARA ESTUDOS DE QUALIDADE DA ENERGIA UTILIZANDO REDES NEURAIAS ARTIFICIAIS

Márcio Arvelos Moraes, José Carlos de Oliveira, Raquel C. Filiagi Gregory, Camilla de Sousa Chaves
Universidade Federal de Uberlândia, Núcleo de Qualidade da Energia Elétrica (NQEE), Uberlândia – MG.
marcio.arvelos@gmail.com, jcoliveira@ufu.br, raquel.filiagi@gmail.com, kmillachaves@yahoo.com.br

Resumo – Por motivos amplamente conhecidos, a qualidade da energia elétrica fornecida aos consumidores se apresenta, no cenário da engenharia elétrica, como tema de suma importância. Quanto a origem dos fenômenos responsáveis pela degradação da qualidade dos suprimentos, esta pode estar relacionada à própria rede de suprimento, ou às cargas por ela supridas, sendo manifestada pelo seu comportamento não-linear, a exemplo das largamente utilizadas lâmpadas fluorescentes compactas - LFC. Muito embora o reconhecimento do fato que, individualmente, estes dispositivos se apresentam com reduzido consumo de energia elétrica e considerável eficiência, estas cargas têm proliferado de forma exponencial nas mais diversas instalações consumidoras, podendo contribuir, sobremaneira, para o aumento do nível das distorções harmônicas presentes no sistema elétrico. O ponto focal do artigo está no emprego de uma ferramenta matemática robusta e versátil, conhecida como rede neural artificial, com o propósito de desenvolver um modelo consistente de uma lâmpada fluorescente compacta a ser aplicado para estudos futuros no que tange a qualidade da energia elétrica.

Palavras-Chave – Carga não-linear, lâmpada fluorescente compacta, modelagem, redes neurais artificiais.

MODELING A COMPACT FLUORESCENT LAMP USING ARTIFICIAL NEURAL NETWORK

Abstract - For well-known reasons, the quality of the electricity supplied to consumers is presented in the scenario of electrical engineering, as a matter of paramount importance. As the origin of the phenomena responsible for the degradation of the provision quality, this can be related to the own feeder system or to loads supplied by it. In this large context, this work aims to model a compact fluorescent lamp - CFL, which knowingly presents a nonlinear behavior and impacts on indicators of harmonic distortion. Although recognition of the fact that, individually, these devices present reduced power consumption and considerable efficiency, they have

exponentially proliferated in several end users facilities. The focal point of the article is to employ a robust and versatile mathematical tool known as artificial neural network, in order to develop a consistent model of a CFL to be applied in future studies.

Keywords – Artificial neural network, compact fluorescent lamp, modeling, non-linear load.

I. INTRODUÇÃO

A análise da corrente elétrica solicitada por uma carga é extremamente relevante, visto sua pronta correlação com os indicadores de qualidade da energia elétrica. Quando do suprimento de cargas não lineares ou outras com peculiaridades operativas que destoam dos comportamentos teóricos previstos para as denominadas cargas lineares, uma série de efeitos indesejáveis podem ocorrer, a exemplo de distorções harmônicas, afundamento de tensão, baixo fator de potência e entre outros [1].

Focando especificamente na natureza das cargas que contribuem para os fenômenos supra mencionados, surge, de imediato, os dispositivos eletrônicos. Estes apresentam como vantagens uma melhor eficiência e controlabilidade aos mais diversos fins a que se destinam. Mediante estas características, o interesse por esse tipo de dispositivo é crescente, fomentando mais investimento na produção e desenvolvimento de novas tecnologias. Através disto, os equipamentos eletrônicos se popularizaram e atualmente representam grande parcela das cargas residenciais, comerciais e industriais. Contudo, as distorções de corrente provocadas por tais equipamentos têm se tornado um problema de proporções consideráveis.

Visando estudos avaliativos de desempenho quando da presença destas cargas, várias estratégias foram desenvolvidas e se apresentam como procedimentos em franco uso no cenário da engenharia elétrica. A exemplo disto, citam-se os tratamentos destas via fontes de correntes ou tensão harmônicas, modelos matemáticos, impedância e fonte de corrente [2], modelos probabilísticos [3] etc.

O modelo de fontes de correntes harmônicas, devido a sua simplicidade de cálculo, se apresenta como uma proposta de grande difusão e com aceitável precisão nos resultados. Porém, este método não leva em consideração o mecanismo iterativo existente quando uma determinada carga não-linear é suprida por fontes de tensão distorcidas [3], [4]. Efetivamente, as denominadas fontes de corrente são derivadas de uma alimentação puramente senoidal e as componentes harmônicas assim produzidas permanecem imutáveis ao longo dos estudos, fato este inconsistente com a realidade.



XIII CEEL - ISSN 2178-8308
12 a 16 de Outubro de 2015
Universidade Federal de Uberlândia - UFU
Uberlândia - Minas Gerais - Brasil

Diante do exposto, uma estratégia para contornar a questão da interdependência supra apontada está na modelagem da carga não linear utilizando Redes Neurais Artificiais – RNA. Esta é uma ferramenta matemática versátil e robusta, criada em meados do século passado e que vem sendo estudada e desenvolvida intensamente nas últimas décadas.

Nesta conjuntura, o presente trabalho tem por objetivo principal desenvolver um modelo consistente de uma LFC utilizando redes neurais, com o propósito de empregar tal modelo em estudos correlatos no futuro.

II. ALGUNS CONCEITOS SOBRE REDES NEURAIS ARTIFICIAIS

Alguns pesquisadores (*Warren McCulloch e Walter Pitts*) [5] durante a década de 40, desenvolveram técnicas computacionais inspiradas nas estruturas neurais dos seres vivos. Estas são conhecidas como Redes Neurais Artificiais e apresentam modelos matemáticos que representa conexões sinápticas equivalentes a de um neurônio biológico.

Um conjunto extremamente complexo de células, os neurônios, formam o sistema nervoso, desempenhando um papel primordial na determinação do comportamento e funcionamento do corpo humano e do raciocínio. Os neurônios são formados por dendritos (conjunto de terminais de entrada presentes pelo corpo celular), núcleo e axônios (longos terminais de saída) [6].

A comunicação entre os neurônios é realizada através da sinapse, que corresponde a região entre dois neurônios que entram em contato através de impulsos nervosos. Quando um neurônio qualquer “A” recebe um impulso nervoso, este é processado e disparado quando atinge um limiar de ação. Isso, faz com que o neurônio produza uma substância neurotransmissora que flui do corpo celular para o axônio, onde os dendritos de um neurônio “B” podem estar conectados, de acordo com [7].

Os neurônios artificiais utilizados nos modelos de *Redes Neurais Artificiais – RNA’s* – são não-lineares e fornecem saídas tipicamente contínuas. Tais neurônios realizam funções simples, como coletar os sinais existentes em suas entradas e agregá-los de acordo com sua função operacional, de modo a produzir uma resposta considerando sua função de ativação inerente [5].

A Figura 1 [8] representa um neurônio artificial e suas partes constituintes. Assim, os sinais de entrada advindos do meio externo são espalhados pelo conjunto $\{x_1, x_2, x_3, \dots, x_m\}$, que são análogos aos impulsos elétricos externos captados pelos dendritos no neurônio biológico.




Fig. 1. Neurônio artificial e seus constituintes.

O conjunto de pesos sinápticos $\{w_1, w_2, w_3, \dots, w_m\}$ do neurônio artificial é equivalente às ponderações exercidas pelas junções sinápticas do modelo biológico. Portanto, cada uma das entradas $\{x_i\}$ do neurônio será multiplicada pelos respectivos pesos sinápticos $\{w_i\}$ dependendo da sua relevância. Em assim sendo, a saída do corpo celular artificial pode ser definida como a soma ponderada de suas entradas.

Portanto, verifica-se que o neurônio artificial é constituído de sete elementos básicos, ou seja:

- Sinais de Entrada $\{x_1, x_2, x_3, \dots, x_m\}$;
- Pesos Sinápticos $\{w_1, w_2, w_3, \dots, w_m\}$;
- Combinador Linear $\{\Sigma\}$;
- Limiar de Ativação (*Bias*) $\{\theta\}$;
- Potencial de Ativação $\{u\}$;
- Função de Ativação $\{g\}$;
- Sinal de Saída $\{y\}$.

A forma com a qual os diversos neurônios de uma rede estão arranjados entre si é denominada arquitetura da rede. Os neurônios são organizados de forma a direcionar as suas conexões sinápticas.

As redes sem realimentação (*feedforward*) o sinal percorre a rede em uma única direção, da entrada para a saída. Os neurônios da mesma camada não são conectados, como mostra a Figura 2 [9].




Fig. 2. RNA *feedforward*

O treinamento de uma arquitetura específica é formado pela aplicação de um conjunto de passos ordenados com o intuito de ajustar os pesos e os limiares de seus neurônios. Assim, tal processo de ajuste, também conhecido como algoritmo de aprendizagem, visa, então, sintonizar a rede para que as suas respostas estejam próximas dos valores desejados. O treinamento supervisionado é uma estratégia que necessita ter disponível um conjunto de sinais de entrada e as respectivas saídas desejadas, para que a partir destas a rede possa formular as hipóteses sobre o que se deve aprender.

As redes *Perceptrons Multicamadas* PMC são um dos exemplos de arquitetura *feedforward*, sendo derivação das redes *Perceptrons* de camada única propostas por *Rosenblatt*. Estas apresentam várias camadas em sua estrutura e são capazes de trabalhar com dados que não são linearmente separáveis, ou seja, dispõem de poder computacional extraordinário quando comparado com o de redes sem camada intermediária. Os pesquisadores *Lang&Hinton* [10] foram os idealizadores das redes PMC de entradas atrasadas no tempo, isto é, as entradas posteriores possuem um atraso no tempo em relação às entradas anteriores. Estas se enquadram dentro da arquitetura *feedforward* de camadas múltiplas sem que haja realimentação das saídas de neurônios de camadas posteriores em direção aos da primeira camada, como mostra a Figura 3.




Fig. 3. PMC com entradas atrasadas no tempo

Para realizar a previsão ou predição de valores futuros, em um determinado instante t , a rede utiliza o seu conhecimento dos valores anteriores, isto é:

$$x(t) = f(x(t-1), x(t-2), \dots, x(t-n_p)) \quad (1)$$

Onde; n_p – ordem do preditor.

O termo n_p , corresponde a quantidade de amostras anteriores que serão usadas para estimar o valor $x(t)$. Diante do exposto, a escolha por uma rede PMC se deu pelo fato de que em se tratando de RNA's com estruturas *feedforward*, somente, as que possuem camadas intermediária são capazes de mapear e solucionar problemas complexo, diferentemente das de camada única que só são capazes de lidar com problemas linearmente separáveis.

III. ESTUDO DE CASO

De acordo com o propósito estabelecido no presente trabalho, esta seção se apresenta com o intuito de desenvolver as técnicas de redes neurais empregando uma rede PMC com entradas atrasadas no tempo, a fim de modelar uma LFC.

A estrutura física utilizada compreendeu uma bancada constituída pelo arranjo ilustrado na Figura 4, cuja montagem experimental encontra-se mostrada na Figura 5.




Fig. 4. Estrutura laboratorial para o ensaio da lâmpada



Fig. 5. Montagem experimental.

Os recursos laboratoriais empregados foram:

- 1 Lâmpada fluorescente compacta FLC® 34W, 127V e FP de 0,55;
- Fonte de tensão controlada HP 6834A Vrms 300 V, 4500VA;
- Osciloscópio Tektronix – TPS 2024
- Microcomputador com o programa Matlab® instalado.

Utilizando o arranjo estabelecido, foram realizados alguns ensaios para obter a forma de onda da corrente da lâmpada. Dentre os experimentos realizados, apresenta-se, para fins deste trabalho, aqueles associados com duas condições operacionais, a saber:

Condição 1 – suprimento da lâmpada com uma tensão puramente senoidal e com valor nominal;

Condição 2 – suprimento com tensão contendo uma pré-distorção harmônica.

Os resultados correspondentes a estes testes encontram-se sintetizados na seqüência.

A. Condição 1

As formas de ondas de tensão e corrente obtidas para esta condição são apresentadas pela Figura 6 e Figura 7, respectivamente.




Fig. 6. Forma de onda da tensão




Fig. 7. Forma de onda da corrente

Através da Figura 7, é possível perceber que a forma de onda da corrente da LFC é significativamente distorcida em comparação a da tensão, o que permite inferir que este sinal apresenta um elevado conteúdo harmônico. A Figura 8 apresenta o espectro harmônico de corrente da LFC, onde os correspondentes valores das distorções individuais (DII) e da distorção total de corrente (DTI) encontram-se fornecidos na Tabela I.

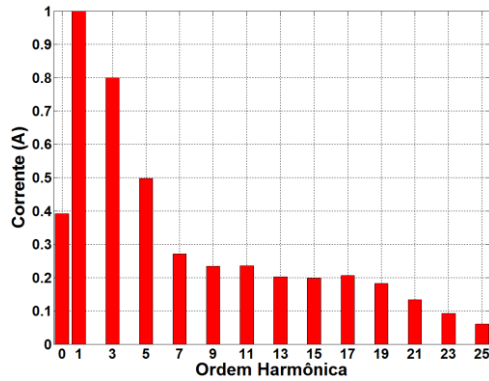


Fig. 8. Espectro harmônico da corrente

Tabela I – DII e DTI da LFC

Ordem	Frequência [Hz]	DII(%)
0	0	39,2
3	180	79,9
5	300	49,8
7	420	27,1
9	540	23,4
11	660	23,6
13	780	20,2
15	900	19,8
17	1020	20,5
19	1140	18,2
21	1260	13,4
23	1380	9,3
25	1500	6,1
-	DTI(%)	112,1

De posse dos dados coletados através do experimento, foi realizada a modelagem da LFC por meio do método das redes neurais utilizando a arquitetura PMC com entradas atrasadas no tempo. Para tanto, o sinal de tensão foi definido como sendo os dados de entrada e o de corrente como os de saída.

Para a criação da rede propriamente dita, tem-se a necessidade de determinar a quantidade de amostra de entradas atrasadas no tempo e o número de neurônios que constituem a camada intermediária da rede. Em vista disto, adotou-se o valor de 100 entradas e 15 neurônios. Os valores, ora referidos,

foram determinados por meio de sucessivas tentativas, até que o desempenho da rede atingisse resultados satisfatórios.

Após a criação a rede, se fez necessário treiná-la. Por conseguinte, optou-se por um treinamento supervisionado, o qual consiste em fornecer à rede os valores de saídas correspondentes aos de entradas. Além disso, utilizou-se o algoritmo *backpropagation* que realiza o ajuste dos pesos da PMC na direção contrária ao gradiente da função erro quadrático. Porém, a utilização deste algoritmo exige elevado esforço computacional, pois converge muito lentamente. Em assim sendo, visando melhor o desempenho deste, vários métodos foram criados, destacando-se o algoritmo de *Levenberg-Marquardt*, o qual consiste em um método gradiente de segunda ordem, baseado no método dos mínimos quadrados não-lineares.

A Figura 9 mostra o processo de treinamento, bem como, informações sobre o gradiente, performance, iterações (épocas) necessárias para treinar e validar a rede.

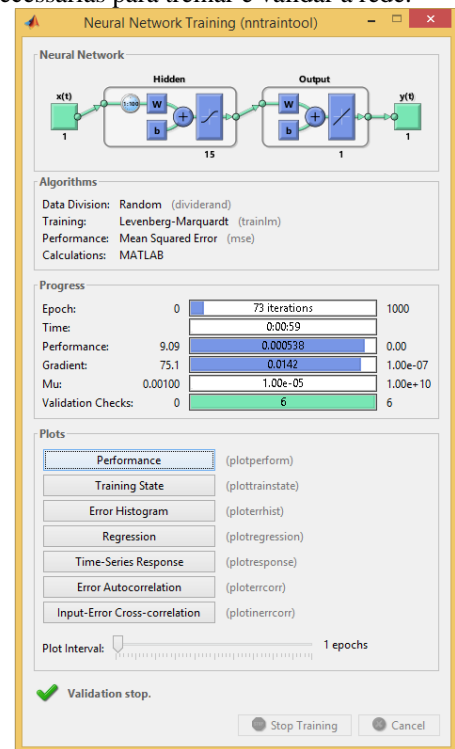


Fig.9. Janela de treinamento da RNA.

Ao término do treinamento e validação da rede, foi possível, então, obter o resultado da corrente da LFC simulada, como pode ser visto na Figura 10. Esta indica a saída da rede e o valor esperado.




Fig. 10. Corrente obtida pela simulação e o erro correspondente

A Figura 11 apresenta a curva do erro quadrado médio em função das iterações do processo de treinamento e validação, e indica em qual delas ocorreu o menor erro.

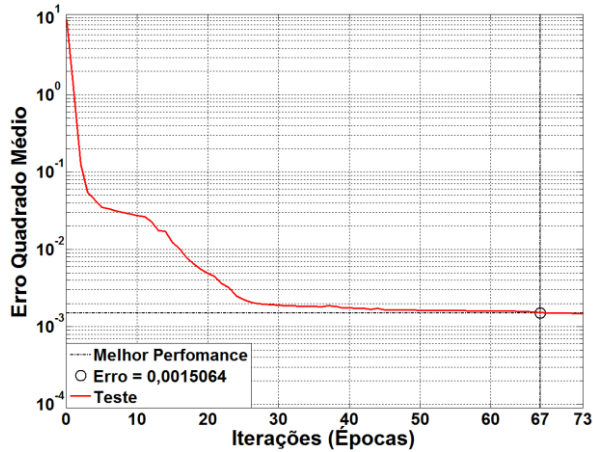


Fig. 11. Curva da performance da rede

B. Condição 2

Para esta condição de ensaio, foi utilizada uma tensão distorcida, composta por três ordens harmônicos, que resultou na forma de onda expressa na Figura 12. Esta apresenta a correlação física entre uma tensão distorcida suprindo a carga não-linear sob análise.




Fig. 12. Forma de onda da tensão distorcida que alimenta a LFC.

A Figura 13 representa a forma de onda da corrente da LFC para a condição 2.




Fig. 13. Forma de onda da corrente da LFC.

O espectro harmônico da tensão de entrada é mostrado na Figura 14 e as distorções harmônicas individuais (DIT) e distorção total de tensão (DTT) estão dispostas na Tabela II.

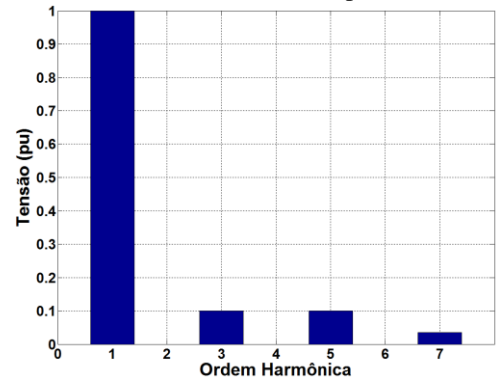


Fig. 14. Espectro harmônico da tensão que alimenta a LFC.

Tabela II – DIT e DTT que alimenta a LFC

Ordem	Frequência [Hz]	DIT(%)
3	180	10
5	300	10
7	420	3,5
-	DTT(%)	14,6

Quanto as distorções presentes na forma de onda da corrente, estas encontram-se destacadas na Figura 15.

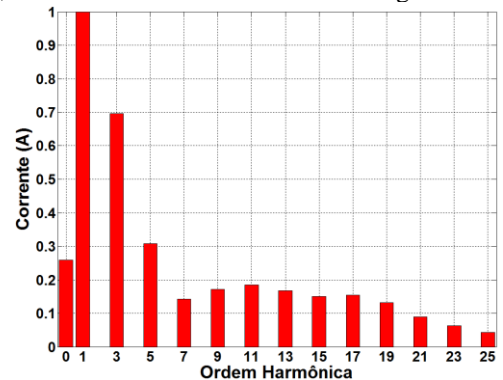


Fig. 15. Espectro harmônico de corrente da LFC.

A Tabela III apresenta o valor das distorções individuais de corrente da LFC.

Tabela III - DIT e DTT da LFC

Ordem	Frequência [Hz]	DIT(%)
0	0	26,0
3	180	69,6
5	300	30,9
7	420	14,2
9	540	17,2
11	660	18,4
13	780	16,7
15	900	15,0
17	1020	15,5
19	1140	13,1
21	1260	9,0
23	1380	6,3
25	1500	4,4
-	DTI(%)	87,8

Com a rede já criada e treinada, foram inseridos os novos valores de tensão de entrada, fato este que resultou na corrente de saída ilustrada na Figura 16. Nesta também encontram-se apresentados os valores esperados a cada saída.

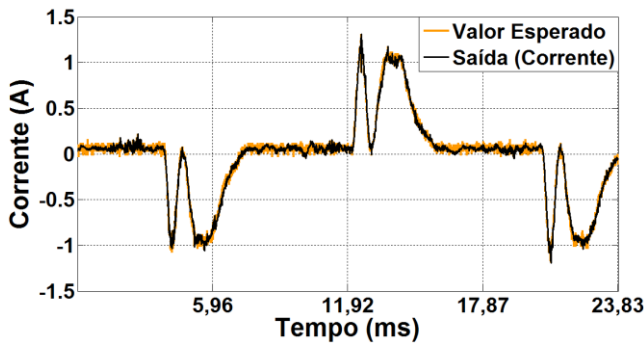


Fig. 16. Corrente obtida na simulação e o erro correspondente

A melhor performance ocorreu na iteração número 62, que apresentou o erro de 0,003655, como mostra a Figura 17.

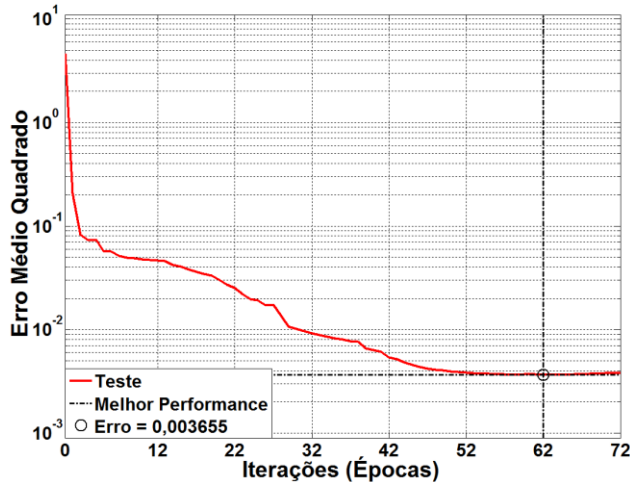


Fig.17. Curva da performance da rede.

Portanto, comparando as Figuras 13 e 16, é possível perceber a semelhança entre o sinal de corrente real e o simulado. Com isso, pode-se afirmar que o modelo da LFC aqui proposto apresentou-se bastante satisfatório.

IV. CONCLUSÃO

Em consonância com os objetos traçados, a tônica do presente artigo foi direcionada para a utilização de recursos associados com a utilização da técnica de modelagem baseada em RNA, visando a representação de lâmpadas LCF.

O fato motivador desta busca foi a disponibilização de meios para representar a geração de correntes harmônicas por este componente, considerando-se o seu suprimento através de tensões previamente distorcidas. Isto se apresenta como ponto alto do artigo, visto que, tradicionalmente, estes cálculos são realizados a partir da premissa de uma rede de alimentação equilibrada. Tendo pois em mente que esta última condição é praticamente impossível de existir, considera-se relevante a interação ora considerada. Isto pode ser ratificado quando se considera, por exemplo, os níveis das distorções harmônicas de corrente encontrados para os dois casos considerados nos estudos. Como se percebe, há diferenças acentuadas entre os

resultados. O indicador, DTI, para o Caso 1 foi de 112,1% enquanto que para o Caso 2 foi de 87,8%. Estes valores, por si só, ratificam a relevância de se considerar a interdependência entre a tensão de suprimento e a geração das correntes harmônicas para o dispositivo em pauta.

Os resultados obtidos evidenciaram a possibilidade da obtenção de modelos mais coerentes para as lâmpadas, fato este importante para os estudos de qualidade da energia elétrica. Diante destas constatações, fica demonstrado que os recursos associados com RNA se mostram promissores aos trabalhos de modelagem e propagação harmônica nas redes elétricas.

V. REFERÊNCIAS

- [1] ANEEL, “Procedimento de Distribuição de Energia Elétrica no Sistema Elétrico Nacional (PRODIST - Módulo 8),” 2015.
- [2] Z. L. Z. S. Wenbo SU, “The Harmonic Calculation Model Of Non-Linear Load,” *China International Conference on Electricity Distribution*, pp. 23-26, 2014.
- [3] O. T. T. Yahia Bagzouz, “Probabilistic Modeling of Power System Harmonics,” *IEEE Transactions*, pp. 173-180, 1987.
- [4] N. K. Carlos F.M. Almeida, “Modelagem de Carga Harmônica Agregada por Circuitos Equivalentes de Norton Acoplados,” *IX CBQEE*, pp. 769-774, 2011.
- [5] I.N. da Silva et al, *Redes Neurais Artificiais Para Engenharia e Ciências Aplicadas: Curso Prático*, São Paulo: ArtLiber, 2010.
- [6] A. P. d. L. F. d. Carvalho, “Icmc Usp,” 04 03 2009. [Online]. Available: <http://www.icmc.usp.br/~andre/research/neural/>. [Acesso em 27 04 2015].
- [7] “Comunicação entre neurônios e representação dos neurotransmissores,” [Online]. Available: doutormadrid.blogs.sapo.pt/12893.html. [Acesso em 2015].
- [8] “Neurônio artificial e seus constituintes,” [Online]. Available: http://www.scielo.br/scielo.php?pid=S0370-44672005000400011&script=sci_arttext. [Acesso em 2015].
- [9] “RNA feedforward,” [Online]. Available: www.cerebromente.org.br/n05/tecnologia/rna.htm. [Acesso em 2015].
- [10] H. G. Lang K.J., “The development of the time-delay neural network architecture for speech recognition,” Pittsburgh, 1988.