

UNIVERSIDADE FEDERAL DE VIÇOSA  
CENTRO DE CIÊNCIAS EXATAS E TECNOLÓGICAS  
DEPARTAMENTO DE ENGENHARIA ELÉTRICA

VINÍCIUS BARROS BARCELOS

**ESTIMAÇÃO DA REAL CONTRIBUIÇÃO HARMÔNICA DE CARGAS  
NÃO-LINEARES UTILIZANDO REDES NEURAIS**

VIÇOSA  
2012

VINÍCIUS BARROS BARCELOS

**ESTIMAÇÃO DA REAL CONTRIBUIÇÃO HARMÔNICA DE CARGAS  
NÃO-LINEARES UTILIZANDO REDES NEURAIS**

Monografia apresentada ao Departamento de Engenharia Elétrica do Centro de Ciências Exatas e Tecnológicas da Universidade Federal de Viçosa, para a obtenção dos créditos da disciplina ELT 490 – Monografia e Seminário e cumprimento do requisito parcial para obtenção do grau de Bacharel em Engenharia Elétrica.

Orientador: Prof. M. Sc. Mauro de Oliveira Prates.

VIÇOSA  
2012



**VINÍCIUS BARROS BARCELOS**

**ESTIMAÇÃO DA REAL CONTRIBUIÇÃO HARMÔNICA DE CARGAS  
NÃO-LINEARES UTILIZANDO REDES NEURAIIS**

Monografia apresentada ao Departamento de Engenharia Elétrica do Centro de Ciências Exatas e Tecnológicas da Universidade Federal de Viçosa, para a obtenção dos créditos da disciplina ELT 490 – Monografia e Seminário e cumprimento do requisito parcial para obtenção do grau de Bacharel em Engenharia Elétrica.

Aprovada em 31 de outubro de 2012.

**COMISSÃO EXAMINADORA**

---

**Prof. M. Sc. Mauro de Oliveira Prates - Orientador**  
**Universidade Federal de Viçosa**

---

**Prof. Dr. José Carlos da Costa Campos - Membro**  
**Universidade Federal de Viçosa**

---

**Prof. M. Sc. Alexandre dos Santos Brandão - Membro**  
**Universidade Federal de Viçosa**

*“Continue procurando ideias novas que outros tenham usado com êxito. Sua ideia tem que ser original somente na adaptação a seu problema.”*

*Thomas Edison*

*Dedico esse trabalho ao meu pai Moisés e minha mãe Ana Beatriz.*

## *Agradecimentos*

Sou eternamente grato aos meus pais Moisés e Ana Beatriz pela educação, corretivos e liberdade para fazer minhas escolhas.

Aos meus irmãos Gláucio e Petrus, que são referências na minha vida e que sempre me ajudaram com a experiência de irmãos mais velhos.

À minha namorada Letícia, que sempre me apoiou nos momentos mais difíceis e que nunca deixou de acreditar em mim. Obrigado Binha, sou um homem melhor por sua causa.

À galera do curso de Engenharia Elétrica, em especial aos amigos do Grupo de Estudos do Chicão - GEC e do Grupo de Estudos do Jorge – GEJ, (Dudera, Leita, Chicó, Jorge e Parabaz) pelos enriquecedores debates e gargalhadas em véspera de provas (pena que as provas não abordavam esses interessantes assuntos).

Aos amigos da república, que sempre torciam pra eu ficar mais um semestre. É galera, não teve jeito, dessa vez estou indo embora.

E por fim, ao meu orientador Mauro Prates pela boa vontade e pelas dicas valiosas ao me orientar nesse trabalho.

## *Resumo*

A distorção harmônica causada por cargas não-lineares é um importante problema para as concessionárias de energia elétrica. O aumento do uso destas cargas, especialmente as advindas de aplicações da eletrônica de potência, resultou em um aumento direto da distorção harmônica nos sistemas elétricos de potência nos últimos anos. Com isso, o uso de novas técnicas computacionais para a modelagem destas cargas passou a ser de grande interesse para este fim. Este trabalho descreve uma metodologia baseada em técnicas de Inteligência Computacional (Redes Neurais Artificiais) para a modelagem de cargas não-lineares, bem como a estimação de sua contribuição harmônica. Este método tem como principal vantagem o fato de que apenas as formas de onda de tensão no ponto de acoplamento comum e a corrente na carga precisam ser medidas, além disso, esta técnica pode ser aplicada na modelagem de cargas monofásicas e trifásicas. O método foi aplicado em duas cargas não-lineares, a fim de se obter a contribuição harmônicas das mesmas. As redes neurais artificiais mostraram um grande potencial para a resolução do problema proposto.



## *Lista de Figuras*

Figura 1 – Ilustração de um Sistema de Distribuição de Energia Elétrica .....	13
Figura 2 – O Neurônio Biológico .....	16
Figura 3 - Neurônio de McCulloch e Pitts, no qual $\Sigma$ representa a soma ponderada das entradas e $\varphi$ a função de ativação. ....	17
Figura 4 - Classificação das RNA. (a) Rede de camada única (feed-forward) (b) Rede multicamadas (feed-forward) (c) Rede feedback .....	18
Figura 5 – Arquitetura das Redes MLP .....	19
Figura 6 – Rede TDNN .....	20
Figura 7 - Corrente distorcida causada por uma carga não-linear .....	21
Figura 8 - Forma de onda resultante da soma de suas harmônicas.....	22
Figura 9 – Circuito Simulado .....	26
Figura 10 – Tensão Distorcida no PAC.....	26
Figura 11 – Topologia de uma TDNN .....	27
Figura 12 – Rede Neural Feed-Forward.....	28
Figura 13 – Metodologia Aplicada.....	29
Figura 14 – Comparação da corrente esperada com a corrente retornada pela RNA.....	31
Figura 15 – Correntes sobrepostas .....	31
Figura 16 - Comparação da corrente esperada com a corrente retornada pela RNA .....	33
Figura 17 – Correntes sobrepostas .....	33

## *Lista de Tabelas*

Tabela 1 - Valores de referência para DHT .....	22
Tabela 2 – Valores Esperados de DHT .....	30
Tabela 3 - Melhor Configuração da RNA para a Carga Não-Linear 1 .....	30
Tabela 4 - Melhor Configuração da RNA para a Carga Não-Linear 2 .....	32
Tabela 5 – Comparações Entre as Duas Cargas .....	34

## *Lista de Siglas*

**QEE** - Qualidade de Energia Elétrica

**SEP** - Sistema Elétrico de Potência

**PAC** - Ponto de Acoplamento Comum

**ANEEL** - Agência Nacional de Energia Elétrica

**IEEE** – Instituto de Engenheiros Eletricistas e Eletrônicos (do inglês *Institute of Electrical and Electronic Engineers*)

**RNA** – Redes Neurais Artificiais

**MLP** – Perceptron de Múltiplas Camadas (do inglês, *Multi-Layer Perceptron*)

**TDNN** – Rede Neural Diretamente Alimentada Com Atrasos Temporais (do inglês, *Time Delay Neural Network*)

**PRODIST** – Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional

**DHT** - Distorção Harmônica Total

**RNN** – Rede Neural Recorrente (do inglês, *Recurrent Neural Network*)

# Sumário

1	Introdução .....	13
1.1	Motivação .....	14
1.2	Objetivos .....	14
1.3	Estrutura do Texto .....	15
2	Revisão Bibliográfica .....	16
2.1	Redes Neurais Artificiais .....	16
2.1.1	O Neurônio Biológico.....	16
2.1.2	O Neurônio Artificial.....	17
2.1.3	Arquitetura de Redes Neurais .....	18
2.1.4	Aprendizado.....	18
2.1.5	Redes de Múltiplas Camadas .....	19
2.1.6	Predição Por Meio de Atrasos no Tempo .....	20
2.2	Cargas Não Lineares e Harmônicos .....	21
2.2.1	Problemas Causados por Harmônicos.....	23
2.2.2	Controle de Correntes Harmônicas .....	23
3	Metodologia .....	25
3.1	Circuito Simulado .....	25
3.2	Rede Neural Utilizada .....	27
3.3	Treinamento da Rede .....	28
4	Análise de Resultados.....	30
4.1	Resultados para a Carga Não-Linear 1 .....	30
4.2	Resultados para a Carga Não-Linear 2 .....	32
4.3	Comparações com as Duas Cargas.....	34
4.4	Algumas Considerações.....	34
5	Conclusões .....	35
5.1	Sugestões Para Trabalhos Futuros.....	35
	Referências Bibliográficas .....	36

# 1 Introdução

O objetivo de uma concessionária de energia elétrica é fornecer uma tensão senoidal com magnitude e frequência constante. Porém, devido a um número cada vez maior de cargas não lineares, principalmente as advindas da eletrônica de potência, é comum os sinais elétricos dos sistemas de distribuição apresentarem algum tipo de distorção na forma de onda de tensão.

A Qualidade da Energia Elétrica (QEE) está diretamente ligada a vários parâmetros relativos à forma de onda de tensão, que quando distorcidas, caracterizam a presença de alguns problemas, como os harmônicos. Tais problemas causam prejuízos a todos os tipos de consumidores (residenciais, comerciais e industriais), e os mesmos estão mais atentos aos limites que não devem ser excedidos pelas concessionárias, pois estão a par dos prejuízos que essas anormalidades podem causar. A culpa, porém, não é somente das concessionárias, já que parte das distorções é devida às cargas não lineares do lado dos consumidores. Com isso, as responsabilidades pela geração de harmônicos demanda investigação mais detalhada.

Podem-se citar vários problemas causados pelas distorções harmônicas, como: perdas adicionais por efeito Joule na rede elétrica e em motores, interferências em sistemas de comunicação, ressonância em bancos de capacitores, diminuição da potência nominal e vida útil de transformadores, entre outros. Desse modo, é de suma importância a localização da fonte de harmônicos nos Sistemas Elétricos de Potência (SEP).

A Figura 1 ilustra um sistema de distribuição, onde três consumidores industriais são conectados no mesmo ponto. Esse ponto é definido como Ponto de Acoplamento Comum (PAC). Quando várias cargas não-lineares estão conectadas no PAC, fica difícil prever matematicamente o quanto cada carga está afetando ou sendo afetada pela distorção harmônica.

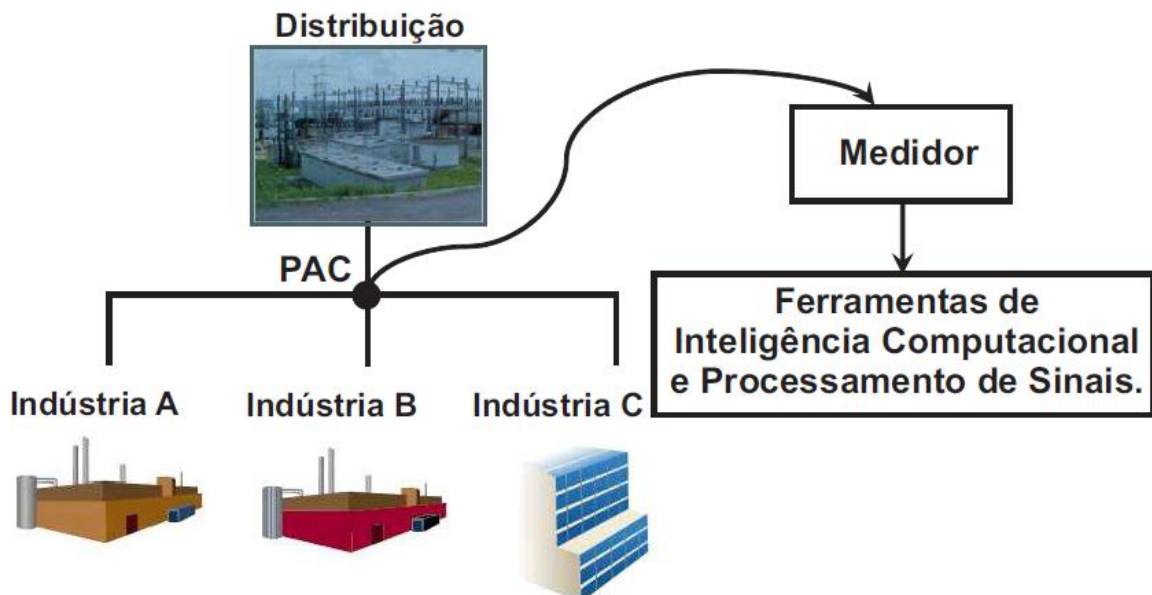


Figura 1 – Ilustração de um Sistema de Distribuição de Energia Elétrica.

Nesse contexto, esse trabalho visa aplicar técnicas de Inteligência Computacional (Redes Neurais Artificiais) para realizar a modelagem das cargas não-lineares desses

consumidores, além de estimar a contribuição harmônica de cada um. O método é bastante vantajoso, pois, o processamento é realizado a partir dos sinais de tensão medidos no PAC e dos sinais de corrente medidos na carga, não sendo necessário, portanto, a remoção da carga do SEP.

Feita a modelagem e a estimação da contribuição harmônica, a Agência Nacional de Energia Elétrica (ANEEL) juntamente com as concessionárias de energia podem criar normas específicas para punir os consumidores que ultrapassem os limites estabelecidos.

## 1.1 Motivação

A norma IEEE Std 519-1992 do *Institute of Electrical and Electronic Engineers* (IEEE) trata da divisão de responsabilidades entre consumidores e concessionárias de energia elétrica. O controle de harmônicos no SEP é feito da seguinte forma: supõe-se que a quantidade de harmônicos injetada no sistema é devido às cargas não-lineares dos consumidores, logo é de responsabilidade do consumidor o controle dessas injeções. Assumindo que a injeção de harmônicos esteja dentro dos limites estabelecidos pelas normas, a concessionária fica responsável pelo controle da distorção harmônica, instalando filtros com o intuito de corrigir o problema [15].

Porém, com a tensão no PAC distorcida, a corrente que passa pela carga do consumidor não representa apenas a contribuição harmônica inserida pela própria carga. Esse fato leva a questionamentos, como: Quem é o responsável pelo excesso de distorções harmônicas?

Assim, com a dificuldade por parte das concessionárias de identificar a origem das contribuições harmônicas, surge a necessidade do desenvolvimento de um método que seja capaz de identificar com facilidade e precisão as fontes dessas contribuições, assim como as parcelas de cada uma delas.

## 1.2 Objetivos

O presente trabalho tem como objetivo principal desenvolver um método para a modelagem de cargas não-lineares e estimação de sua real contribuição harmônica, por meio da medição dos sinais de tensão e corrente no ponto de acoplamento comum em um sistema de distribuição.

Tem-se como objetivos específicos:

- Simular um circuito com cargas não lineares no software MATLAB através da ferramenta Simulink.
- Desenvolver um algoritmo no software MATLAB para definir qual a melhor configuração de rede neural artificial a ser utilizada.
- Estimar a contribuição harmônica das cargas não-lineares a partir dos modelos matemáticos obtidos.

### ***1.3 Estrutura do Texto***

Esse trabalho foi dividido em 5 capítulos.

O capítulo 2 é uma revisão bibliográfica sobre: Cargas Não-Lineares, Harmônicos e Redes Neurais Artificiais (RNA).

O capítulo 3 trata da metodologia utilizada para a modelagem das cargas não-lineares. Nele é apresentado o circuito simulado e a topologia da rede treinada.

O capítulo 4 mostra os resultados obtidos pela metodologia utilizada para a modelagem de duas cargas, sendo a primeira carga constituída por um resistor e um indutor, ligados em série, alimentados por um retificador de onda completa, e a segunda consiste em um resistor e um indutor, ligados em série, alimentados por um TRIAC com ângulo de disparo de 90°.

No capítulo 5 serão apresentadas as conclusões gerais desse trabalho, assim como algumas propostas para a continuidade dessas pesquisas.

## 2 *Revisão Bibliográfica*

Esse capítulo apresentará uma revisão bibliográfica acerca dos principais temas abordados nesse trabalho, sendo eles: Redes Neurais Artificiais, Cargas Não-Lineares e Harmônicos.

### 2.1 *Redes Neurais Artificiais*

A maioria dos computadores atuais seguem o modelo de arquitetura de von Neumann. Tal modelo apresenta um bom desempenho para tarefas usuais como processamento de números e transações. Porém, há uma variedade de aplicações que não são trabalhadas facilmente por essa arquitetura, como reconhecimento de faces, classificação de dados, filtragem de informações, entre outras. Assim, as Redes Neurais Artificiais (RNA) aparecem como uma alternativa às arquiteturas tradicionais [04].

Redes Neurais Artificiais são sistemas paralelos constituídos de unidades de processamento simples (neurônios artificiais), que calculam determinadas funções matemáticas, tanto lineares quanto não lineares. Tais estruturas matemáticas possuem a capacidade de aprender por meio de exemplos e de generalizar as informações aprendidas, extraindo das amostras informações não apresentadas de forma explícita. Essas características fazem com que a solução de problemas através de RNAs seja bastante atrativa.

O processo de aprendizagem consiste em apresentar para a rede um conjunto de exemplos. A rede então extrai características necessárias para representar a informação fornecida, que são utilizadas posteriormente para gerar respostas para o problema. Esse processo de aprendizagem imita o funcionamento do cérebro humano [01] e [02].

#### 2.1.1 *O Neurônio Biológico*

Os neurônios são células do sistema nervoso extremamente especializadas. Possuem, além das estruturas comuns nas demais células, extensões filamentosas (dendritos e axônios) que se desenvolvem a partir do corpo celular, como mostra a Figura 2. Os dendritos recebem os impulsos nervosos e os conduzem até o corpo celular, enquanto os axônios transmitem o sinal para os dendritos de neurônios adjacentes.

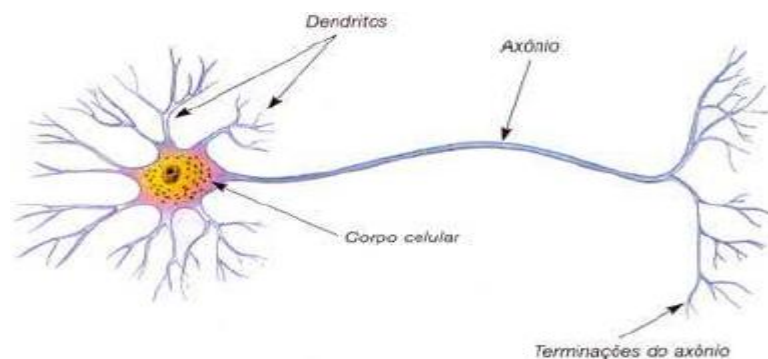


Figura 2 – O Neurônio Biológico.



Como as conexões entre os axônios com os dendritos de outros neurônios ocorrem através de sinapses, os mesmos não chegam a entrar em contato direto. Uma substância química neurotransmissora permite que o impulso atravesse a separação. As conexões sinápticas tem fundamental papel na memorização da informação no cérebro humano [05].

### 2.1.2 O Neurônio Artificial

Warren McCulloch e Walter Pitts desenvolveram em 1943 o primeiro modelo artificial de um neurônio biológico, que era uma simplificação do que se sabia na época a respeito de tais neurônios. O resultado foi um modelo com  $n$  terminais de entrada, que recebem valores  $x_1, x_2, \dots, x_n$ . Esses terminais de entrada representam os dendritos. O modelo possui também um terminal de saída, representando o axônio. Os terminais de entrada do neurônio têm pesos acoplados  $w_1, w_2, \dots, w_n$  (os valores podem ser positivos ou negativos), para representar o comportamento das sinapses.

No modelo artificial, assim como no biológico, a sinapse ocorre quando a soma dos impulsos que ele recebe ultrapassa o seu limiar de excitação. Um mecanismo simples, chamado “função de ativação”, faz a soma dos valores  $x_i w_i$  recebidos e decide se o neurônio deve ou não disparar, como pode ser visto na Figura 3.

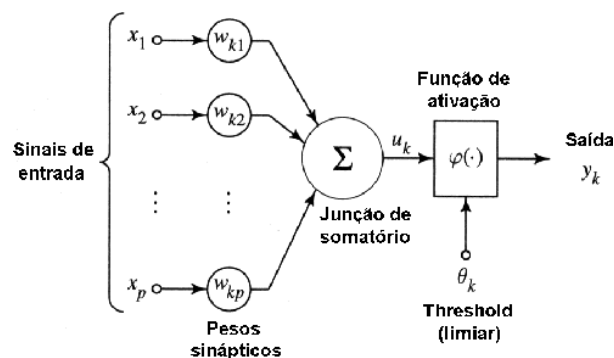


Figura 3 - Neurônio de McCulloch e Pitts, no qual  $\Sigma$  representa a soma ponderada das entradas e  $\varphi(\cdot)$  a função de ativação.

A saída  $y_k$  do neurônio de McCulloch e Pitts pode ser equacionada por:

$$y = \varphi\left(\sum_{i=1}^n x_i w_i + b\right) \quad (1)$$

onde  $n$  é o número de entradas do neurônio,  $w_i$  é o peso associado à entrada  $x_i$  e  $\varphi$  é a função de ativação.

Uma rede neural é, portanto, formada por neurônios artificiais que atuam como elementos processadores simples. Cada elemento processador executa uma função simples, mas uma rede neural como um todo tem capacidade computacional para resolução de problemas complexos [01] e [02].

### 2.1.3 Arquitetura de Redes Neurais

O tipo de problema que será solucionado está diretamente ligado à forma como os neurônios são organizados em uma RNA, e é fator importante para a definição dos algoritmos de aprendizado. Existem duas categorias básicas para classificar as arquiteturas das RNAs: feed-forward e feed-back, conforme ilustrado na Figura 4. [06].

Para ser considerada feed-forward, a rede neural precisa que suas saídas se conectem somente com as unidades da próxima camada. O surgimento das redes neurais multicamadas revelou o potencial das redes feed-forward [03] e [04].

Em redes feed-back, a saída de uma unidade de processamento pode se conectar a uma de suas próprias entradas ou a uma entrada de outra unidade da mesma camada, ao contrário das redes feed-forward. As redes neurais recorrentes se encaixam nessa classe de arquitetura [03] e [04].




Figura 4 - Classificação das RNA. (a) Rede de camada única (feed-forward) (b) Rede multicamadas (feed-forward) (c) Rede feed-back.

### 2.1.4 Aprendizado

A capacidade de aprender geralmente é o que caracteriza um sistema como rede neural. O processo pelo qual uma RNA adquire a habilidade de responder corretamente a estímulos através do ajuste de parâmetros é chamado de aprendizado, que ocorre quando a RNA atinge uma solução generalizada para uma classe de problemas.

Dois métodos são utilizados para classificar o aprendizado em RNAs, de acordo com a presença ou ausência de realimentação explícita do mundo exterior:

- **Aprendizado supervisionado:** a RNA é treinada através de pares de entradas e saídas. A rede produz uma resposta na saída para cada entrada. Essa resposta é comparada com a resposta desejada e realiza-se o ajuste dos pesos sinápticos através da análise de erros. Isto é normalmente utilizado para redes feed-forward.
- **Aprendizado não supervisionado:** não existe saída desejada. A rede é treinada para arbitrariamente organizar padrões em categorias através de excitações ou padrões de entrada. Para uma entrada aplicada à rede, uma resposta indicando a classe a qual a entrada pertence será fornecida. Caso o padrão de entrada não corresponda às classes existentes, uma nova classe será gerada. Isto é normalmente utilizado para redes auto-organizáveis.

As regras de aprendizado são expressões matemáticas que descrevem o processo de treinamento das redes neurais. Entre as regras mais conhecidas, pode-se citar a regra de Hebb

e a regra delta, também conhecida como Least Mean Square (LMS), que minimiza o erro médio quadrático [05].

### 2.1.5 Redes de Múltiplas Camadas

As redes de camada única são limitadas a resolver apenas problemas linearmente separáveis (aqueles que se podem separar os padrões por meio de uma reta), porém, a maioria das situações e problemas reais possuem características não lineares. Com isso, surge a necessidade do uso de estruturas neurais de múltiplas camadas, também conhecida como redes MLP (do inglês, Multi Layer Perceptron), que permitem a aproximação de qualquer função matemática.

As redes do tipo MLP são redes multicamadas, formadas por uma camada de entrada, uma ou mais camadas ocultas, e uma camada de saída. Cada neurônio de uma camada recebe os sinais de todos os neurônios da camada anterior, e propaga sua saída a todos os neurônios da camada posterior. A camada de entrada é utilizada para receber os dados de entrada da rede. Essa camada, portanto, não efetua qualquer tipo de processamento, servindo apenas para receber e armazenar o vetor de entrada. O número de neurônios nessa camada corresponde à dimensão do vetor de entrada. Na camada de saída têm-se as respostas obtidas pela rede. O número de neurônios nessa camada corresponde ao vetor de saída. Entre a camada de entrada e a de saída, pode-se ter uma ou mais camadas ocultas.

As camadas ocultas proporcionam complexidade e não linearidade para a rede. Não existe um método que determine o número ideal de camadas ocultas e de neurônios, porém a escolha desses parâmetros é muito importante e influencia diretamente no desempenho do sistema, pois o tempo computacional para o cálculo da resposta e para o treinamento da rede aumenta consideravelmente com o aumento das conexões e de neurônios nas camadas ocultas [03].

A Figura 5 ilustra as estruturas e conexões de uma rede MLP.

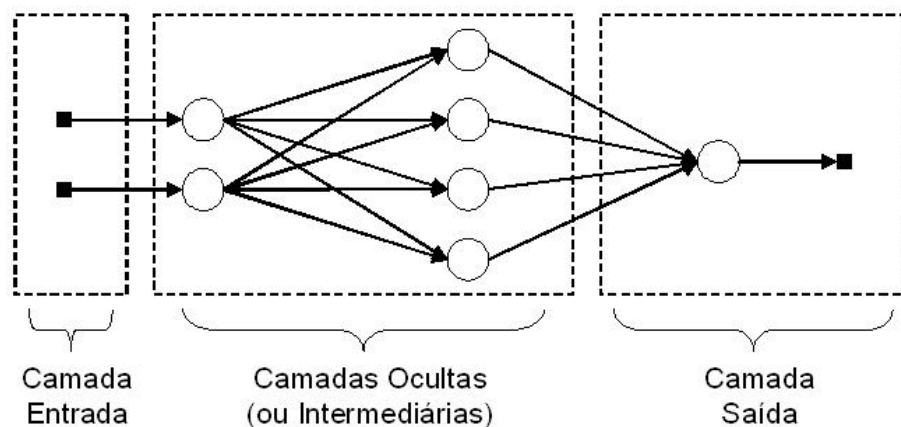


Figura 5 – Arquitetura das Redes MLP.

### 2.1.6 Predição Por Meio de Atrasos no Tempo

A rede neural conhecida como TDNN (do inglês, *Time Delay Neural Network*) é caracterizada pela utilização de uma topologia especial, voltada ao reconhecimento de subpadrões independentes dentro um padrão de entrada contínuo.

A técnica TDNN consiste na introdução de atrasos nos padrões de entrada da rede, sendo usualmente composta por uma camada de entrada, uma ou mais camadas intermediárias e uma camada de saída, conforme ilustra a Figura 6.

Nas redes neurais convencionais, um neurônio é responsável por calcular uma soma ponderada de todas as suas entradas, e, após isso, propaga-la por meio de uma função não-linear (geralmente função de corte ou sigmóide) para as próximas unidades. Na rede TDNN, as entradas são modificadas para introduzir  $n$  atrasos à entrada de dados. Dessa maneira, uma cada de entrada composta por  $y$  elementos gera  $z = y \cdot (n + 1)$  entradas para a rede. Dessa forma, a rede necessita de  $z$  pesos para  $y$  entradas.




Figura 6 – Rede TDNN.

Enquanto em redes neurais convencionais cada neurônio geralmente conecta-se somente uma vez com outro da camada sucessora, no modelo TDNN são realizadas diversas conexões com pesos independentes. Antes do cálculo do peso de cada conexão, os dados sofrem um atraso que os eliminam do cálculo da soma de pesos. Uma vez que cada conexão é associada com um atraso correspondente, as conexões atuam como um mecanismo de memória de curto prazo, possibilitando relatar e comparar o vetor de entrada atual aos dados observados anteriormente.

As saídas de cada camada são computadas e utilizadas como valores de entrada para as camadas sucessoras, até chegar à camada de saída. Os valores de saída são comparados aos valores esperados, calculando o erro, que é propagado pela rede, atualizando os pesos e, conseqüentemente, decrementando o erro global. O procedimento é repetido até a rede convergir para a saída desejada. Dessa maneira, uma predição eficiente somente é possível após o treinamento repetitivo da rede [07].

## 2.2 Cargas Não Lineares e Harmônicos

Os harmônicos são problemas relacionados à QEE que podem prejudicar o funcionamento de equipamentos conectados à mesma fonte de alimentação. Eles injetam no sistema frequências múltiplas inteiras da frequência fundamental da fonte de alimentação, ou seja, para uma fundamental de 60 Hz o quinto harmônico corresponde a 300 Hz, o sétimo a 420 Hz, e assim por diante [09]. Devido ao aumento da aplicação dos dispositivos advindos da eletrônica de potência, a distorção harmônica se tornou uma preocupação crescente entre as concessionárias de energia elétrica [08].

A distorção harmônica é causada por cargas não lineares em um sistema elétrico de potência. Em cargas lineares a relação tensão *versus* corrente é linear, sendo o gráfico uma reta que passa pela origem e tem inclinação igual à resistência ôhmica da carga. Cargas indutivas e capacitivas também são consideradas lineares, pois a relação tensão *versus* corrente se dá através de derivadas ou integrais. Em uma carga não linear, a corrente que passa por ela não é proporcional à tensão aplicada. Com isso, existe uma dificuldade em modelar cargas não lineares devido à complexidade da corrente que apresentam em resposta às tensões impostas. A Figura 7 ilustra esse conceito, onde uma tensão senoidal é aplicada em um resistor não linear, e a relação tensão *versus* corrente varia de acordo com a curva mostrada. Enquanto a tensão aplicada é perfeitamente senoidal, a corrente resultante é distorcida. Um pequeno aumento da tensão pode fazer com que a corrente dobre, levando a diferentes formas de ondas. Esta é a fonte da maioria das distorções harmônicas em um SEP [10].




Figura 7 - Corrente distorcida causada por uma carga não-linear.

A Figura 8 mostra que qualquer forma de onda periódica distorcida pode ser expressa como uma soma de senóides, em que a frequência de cada uma delas é um múltiplo inteiro da frequência fundamental da onda distorcida. Este múltiplo é chamado de um harmônico da frequência fundamental. A soma de senóides é referida como uma série de Fourier, em homenagem ao grande matemático que descobriu o conceito.




Figura 8 - Forma de onda resultante da soma de suas harmônicas.

A Distorção Harmônica Total (DHT) é uma medida global que caracteriza os níveis de distorção harmônica, tomando como base a magnitude de todos os componentes harmônicos, conforme mostra a equação a seguir:

$$DHT = \frac{\sqrt{\sum_{h=2}^{h_{max}} V_h^2}}{V_1} \times 100\% \quad (2)$$

onde  $V_h$  é a amplitude do  $h$ -ésimo componente harmônico,  $h_{max}$  é a ordem do componente harmônico de maior frequência presente no sinal e  $V_1$  é a amplitude da componente fundamental.

O PRODIST (ANEEL,2010) adotou os limites permitidos para a DHT estipulados pela (IEEE-STD.519, 1992). No Brasil, estes valores são utilizados para servir como base de referência do planejamento elétrico em termo de QEE, e que após período experimental, serão estabelecidos em resolução específica. A Tabela 1 apresenta esses limites.

Tabela 1 - Valores de referência para DHT.

Tensão Nominal do Barramento	Distorção Harmônica Total de Tensão (DHT) [%]
$V_N \leq 1 \text{ kV}$	10
$1 \text{ kV} \leq V_N \leq 13,8 \text{ kV}$	8
$13,8 \text{ kV} \leq V_N \leq 69 \text{ kV}$	6
$69 \text{ kV} \leq V_N \leq 230 \text{ kV}$	3

Os componentes harmônicos são encontrados em suas diversas ordens em sinais elétricos de tensão e corrente. Os de ordem ímpar são mais frequentes e podem ser encontrados nas instalações elétricas em geral. Os de ordem par são relativamente raros, aparecendo em situações onde a retificação de meia onda é utilizada [08] e [09].

Uma das principais classes de cargas não lineares nos sistemas elétricos de potência são os conversores estáticos, englobando inversores, *soft-starters* e retificadores [08]. As lâmpadas fluorescentes também apresentam características não-lineares. Elas contam com processo de funcionamento de descargas elétricas a partir de *starter* ou reator, e também descargas elétricas a partir de circuito eletrônico. Representam uma parcela importante na geração de harmônicos, pois são responsáveis por cerca de 40 a 60% da carga elétrica comercial [11].

### 2.2.1 Problemas Causados por Harmônicos

Antigamente, a maior parte das cargas utilizadas possuía características lineares, logo, não se tinha uma grande preocupação com harmônicos. Hoje, com o aumento do uso de cargas não lineares, principalmente as advindas da eletrônica de potência, o efeito dos harmônicos tem aumentado consideravelmente, causando uma série de problemas tanto para o sistema de distribuição quanto para as cargas instaladas [09].

Correntes harmônicas produzidas por cargas não lineares são injetadas de volta nos sistemas de abastecimento. Estas correntes podem interagir negativamente com uma ampla gama de equipamentos, além de prejudicar sistemas de telecomunicações [10].

Como exemplo de problemas causados por correntes harmônicas, podem-se citar:

- Fusíveis e Disjuntores: operação falsa/errônea, além de danos aos seus componentes.
- Capacitores: Aquecimento e redução de sua vida útil devido à ocorrência de efeitos ressonantes. Sobrecorrente em capacitores para correção de fator de potência.
- Motores e Transformadores: Superaquecimento, perdas adicionais, redução da vida útil e impossibilidade de atingir potência máxima.
- Medidores: Erros nas medições.
- Telefones: Ruídos provocados por interferências e mau funcionamento dos aparelhos.
- Efeito Pelicular: As correntes alternadas tendem a fluir na superfície externa do condutor, causando perdas adicionais e aquecimento dos condutores.

### 2.2.2 Controle de Correntes Harmônicas

Atualmente, os filtros passivos e ativos são as medidas disponíveis para o controle da magnitude das correntes harmônicas. Como esse trabalho permite a identificação das principais fontes geradoras de harmônicos, fica simplificada a implantação de filtros corretores nos pontos do sistema que realmente necessitam. Exemplificando, o método pode conduzir a economia no projeto de filtros, pois serão aplicados em trechos menores e mais específicos do sistema elétrico, reduzindo os gastos com seus componentes.

Os filtros passivos possuem o intuito de prover um caminho de baixa impedância para correntes harmônicas. Assim, essas correntes não fluem pela fonte de alimentação para a terra e sim pelo filtro. Dependendo da necessidade, o filtro pode ser projetado para uma única frequência de harmônico ou para uma ampla faixa espectral.

Às vezes se torna necessário projetar um filtro mais complexo para aumentar a impedância em série nas frequências harmônicas, a fim de reduzir a proporção de corrente que volta para a fonte. São comumente propostos filtros rejeita banda, instalados no neutro ou na fase. O filtro em série é adicionado geralmente não para prover um caminho controlado por

elas, e sim para bloquear as correntes harmônicas, logo, podem ocorrer altas quedas de tensão. A queda de tensão ocorre no barramento das cargas, esse fato torna o barramento impróprio para alimentar os equipamentos ligados a ele, apesar de alguns equipamentos serem insensíveis a tais quedas.

Em algumas situações, o conteúdo harmônico da corrente (frequência e corrente) varia ao longo do tempo. Como os filtros passivos operam para uma frequência específica, uma solução conveniente nestes casos é o uso de filtros ativos. Nesses filtros, o conteúdo harmônico da corrente é medido por um transformador de corrente, que controla um gerador que produz uma réplica do sinal harmônico, porém invertido. Com isso, até 90% da magnitude dos harmônicos são reduzidas, e conseqüentemente a distorção na forma de onda de tensão [09].



### 3 Metodologia

A localização de fontes de harmônicos em sistemas elétricos de potência ainda é um problema que não foi elucidado totalmente. Antes de apresentar o método proposto nesse trabalho, cabe colocar a existência de trabalhos técnico-científicos que propõem soluções para este problema.

Em [12] é proposta uma metodologia baseada no princípio da superposição de correntes, para, a partir da análise das contribuições individuais sobrepostas no PAC, determinar a contribuição harmônica do consumidor e da concessionária. Esta abordagem obtém bons resultados, no entanto depende do conhecimento a priori de algumas informações, como a impedância da fonte.

Em [13] é apresentado um método baseado em Redes Neurais Recorrentes (do inglês, Recurrent Neural Networks) para determinar o responsável pelas contribuições harmônicas (consumidor ou fornecedor) quando uma determinada carga é conectada em um PAC com sinal de tensão distorcido. De posse do sinal de tensão medido no PAC e do sinal de corrente medido na carga, a RNN é treinada para modelar a admitância da carga. Após o treinamento, é aplicada na entrada da RNN uma tensão senoidal pura, mostrando que a sua saída seria a corrente que a carga não-linear injetaria na rede caso fosse alimentada com uma tensão puramente senoidal. Conforme atestam os autores, uma tensão senoidal pura não foi apresentada à RNN durante a fase de treinamento.

O método desenvolvido nesse trabalho consiste no uso de técnicas computacionais (Redes Neurais Artificiais) para realizar a modelagem de uma carga não linear, utilizando como base o sinal de tensão medido no PAC e o sinal de corrente medido na carga.

#### 3.1 Circuito Simulado

Os sinais de tensão e corrente utilizados para o treinamento da RNA foram obtidos a partir de um circuito simulado no software MATLAB através da ferramenta Simulink. A Figura 9 mostra o circuito simulado.

A tensão da fonte é de 127 volts RMS e a frequência de operação é de 60 Hz. A fim de simular uma tensão distorcida no PAC, a fonte injeta no sistema o sétimo, o décimo primeiro e o décimo terceiro harmônicos da frequência fundamental. Seus respectivos módulos são 15%, 7,5% e 5% do módulo da frequência fundamental. Esses harmônicos foram escolhidos por serem medida mais frequentes em cargas não-lineares nos sistemas elétricos de potência.

Nota-se na Figura 10 uma grande distorção harmônica, pois a onda de tensão está extremamente diferente da ideal (que é a senóide pura com frequência de 60 Hz).

A carga não-linear 1 da Figura 9 consiste em um resistor de  $10\Omega$  ligado em série com um indutor de 10mH, alimentados por um TRIAC com ângulo de disparo de  $90^\circ$ . A carga não-linear 2 consiste em um resistor de  $10\Omega$  ligado em série com um indutor de 10mH, alimentados por um retificador de onda completa. Essas cargas foram escolhidas devido a sua natureza não-linear e por serem partes integrantes de inversores de frequência e *soft-starters* presentes em grande número nas indústrias.

O voltímetro mede a tensão distorcida no ponto de acoplamento comum e o amperímetro mede a corrente que passa pela carga na qual se deseja estimar sua contribuição harmônica.

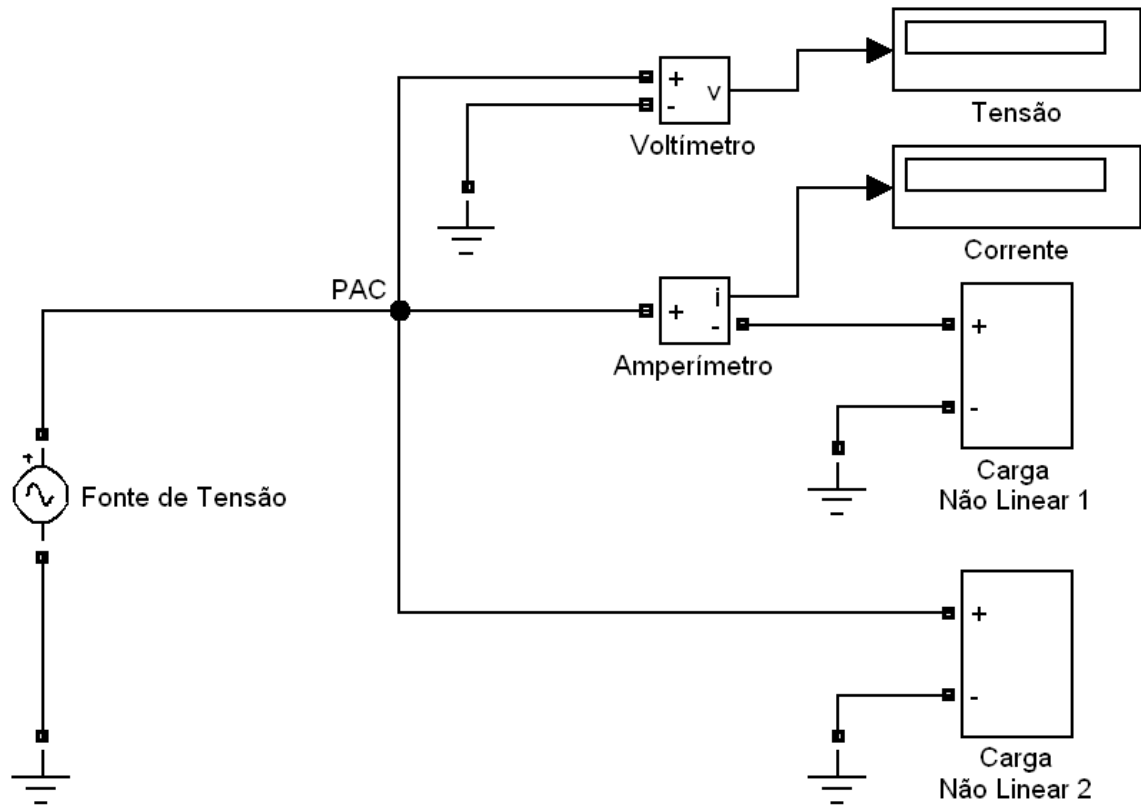


Figura 9 – Circuito Simulado.




Figura 10 – Tensão Distorcida no PAC.

### 3.2 Rede Neural Utilizada

Como dito anteriormente, as redes neurais utilizadas nesse trabalho são conhecidas como TDNN. A Figura 11 representa a topologia de uma TDNN, composta por uma camada de entrada, duas camadas intermediárias e uma camada de saída.




Figura 11 – Topologia de uma TDNN.

Como se vê, a camada de saída é responsável por fornecer o valor predito pela rede neural em função das entradas, ou seja,

$$I(t) = f(V(t), V(t-1), V(t-2), \dots, V(t-n)) \quad (3)$$

Nesse trabalho, foi utilizado  $n=14$ . Assim, o vetor de entrada possui 15 valores, sendo o tempo atual e os últimos quatorze instantes de tempo.

O tipo de rede utilizado foi uma Feed-Forward, com duas camadas intermediárias, como mostra a figura 12.

Os números abaixo das camadas representa o número de neurônios. A letra  $w$  representa o peso sináptico, e  $b$  é o bias, que é usado para aumentar os graus de liberdade, permitindo uma melhor adaptação, por parte da rede neural, ao conhecimento a ela fornecido.

O número de camadas intermediárias se justifica pelo fato de que uma camada intermediária é suficiente para aproximar qualquer função contínua, e duas camadas são suficientes para aproximar qualquer função [14].




Figura 12 – Rede Neural Feed-Forward.

Não há na literatura uma regra geral que determine de forma precisa qual deve ser o número de neurônios de uma rede neural para a resolução de um determinado problema [01]. Com isso, um algoritmo foi criado para que o número de neurônios de cada camada escondida varie a cada ciclo de treinamento, armazenando sempre a última melhor configuração.

Outro parâmetro que o algoritmo varia é a função de transferência de cada camada intermediária. Em [01] afirma-se que, redes MLP se caracterizam pela utilização de funções sigmoideais nas camadas intermediárias e sigmoideais ou lineares na camada de saída. Normalmente as funções lineares na saída serão utilizadas em problemas de aproximação de funções, e as funções sigmoideais em problemas de classificação, apesar de esta não ser uma regra geral. Como esse problema é um problema de aproximação de função, a função de transferência utilizada na saída foi a função linear “purelin”. Assim, o algoritmo varia apenas as funções de transferência das camadas escondidas.

Para esse trabalho, o número de neurônios varia de 1 a 10, e as funções de transferência das camadas intermediárias variam entre as funções sigmoideais “logsig” e “tansig”. Com isso, o algoritmo treina a RNA para todas as combinações possíveis desses parâmetros, a fim de se obter a melhor configuração possível.

### 3.3 Treinamento da Rede

A Figura 13 ilustra a metodologia aplicada.

O método proposto mede os valores instantâneos da tensão ( $V_{\text{distorcida}}$ ) no PAC e da corrente ( $i_{\text{carga}}$ ) na carga. Esses valores são utilizados para realizar o treinamento da rede neural, sendo  $V_{\text{distorcida}}$  a entrada e  $i_{\text{carga}}$  a saída, pois se deseja obter o conteúdo harmônico da corrente. Inicialmente os pesos possuem valores aleatórios, fazendo com que o erro seja grande. Após várias amostras, os pesos se ajustam, diminuindo o erro para um valor aceitável. Nesse ponto, a RNA representa a admitância da carga não linear. Ao aplicar a tensão senoidal na entrada da rede de estimação, simula-se uma situação onde distorção harmônica de tensão no PAC é teoricamente nula. Assim, qualquer distorção harmônica presente no sinal de corrente será devido a contribuições da carga.

De posse dos sinais de corrente fornecidos pela RNA, calcula-se a distorção harmônica total através da equação a seguir.

$$DHT = \frac{\sqrt{\sum_{h=2}^{h_{\max}} I_h^2}}{I_1^2} \times 100\% \quad (4)$$

onde  $I_h$  é a amplitude do  $h$ -ésimo componente harmônico,  $h_{max}$  é a ordem do componente harmônico de maior frequência presente no sinal e  $I_1$  é a amplitude da componente fundamental.

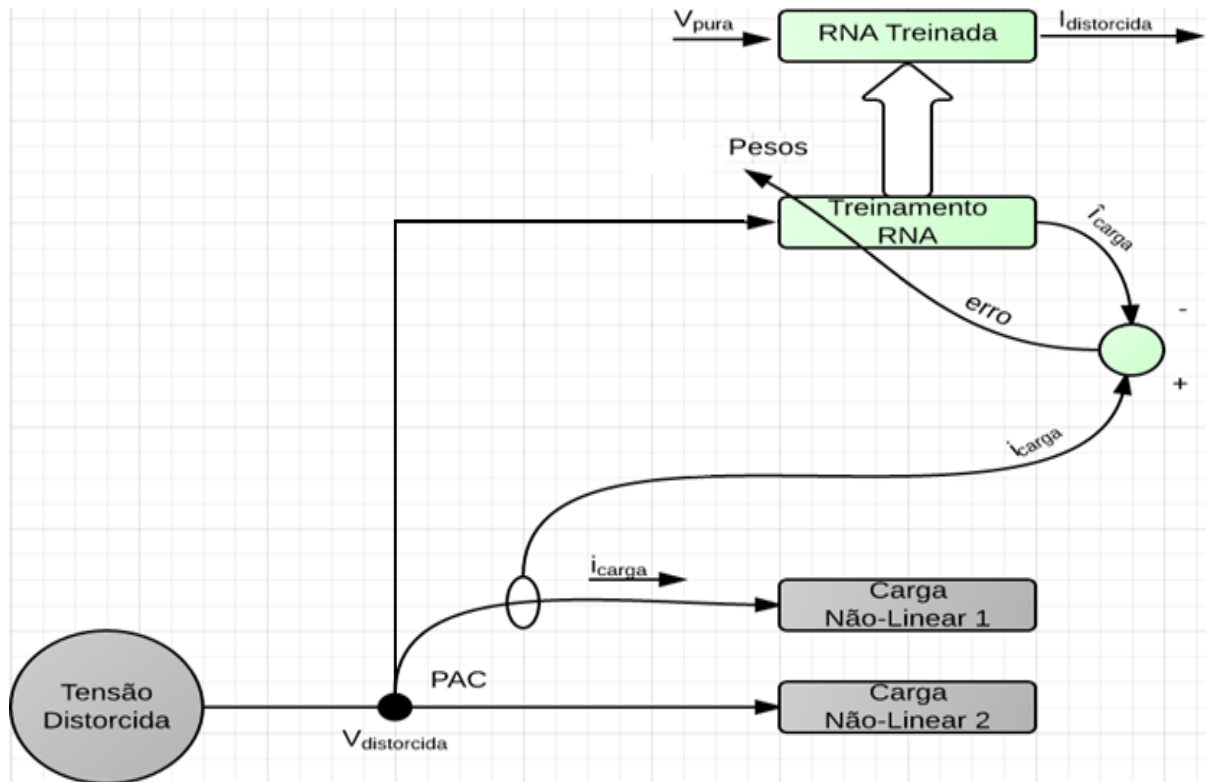


Figura 13 – Metodologia Aplicada.

## 4 *Análise de Resultados*

Nesse capítulo serão apresentados os parâmetros retornados pelo algoritmo para a obtenção da melhor configuração de rede neural para as duas cargas não-lineares utilizadas nesse trabalho. Será mostrado também a corrente que tal rede retorna quando se aplica uma tensão puramente senoidal em sua entrada. Por fim, o cálculo da distorção harmônica total da corrente obtida pela RNA é apresentado.

A Tabela 2 mostra as DHT de corrente esperadas para cada carga não-linear. Esses valores serão utilizados para realizar uma comparação com os valores obtidos com o método desse trabalho.

Tabela 2 – Valores Esperados de DHT.

	<b>Carga Não-Linear 1</b>	<b>Carga Não-Linear 2</b>
<b>DHT</b>	0,4597	0,1723

### 4.1 *Resultados para a Carga Não-Linear 1*

A Tabela 3 apresenta os parâmetros retornados pelo algoritmo para a melhor configuração da RNA para a carga não-linear 1.

Tabela 3 - Melhor Configuração da RNA para a Carga Não-Linear 1.

<b>Número de Neurônios da Camada Intermediária 1</b>	<b>Função de Transferência da Camada Intermediária 1</b>	<b>Número de Neurônios da Camada Intermediária 2</b>	<b>Função de Transferência da Camada Intermediária 2</b>
5	logsig	4	logsig

Ao comparar a corrente obtida com a esperada, o Erro Médio Quadrático encontrado foi de:

$$MSE = 1,5118\%$$

A Figura 14 mostra a corrente retornada pela RNA após aplicar um sinal puramente senoidal na entrada. O gráfico de cima é a corrente esperada e o gráfico de baixo é a corrente retornada pela RNA. Como se vê, o resultado encontrado é muito próximo do esperado, mostrando que a RNA tem capacidade de realizar uma boa modelagem da carga em questão. A Figura 15 mostra essas correntes sobrepostas.




Figura 14 – Comparação da corrente esperada com a corrente retornada pela RNA.




Figura 15 – Correntes sobrepostas.

O próximo passo é o cálculo da distorção harmônica total da corrente retornada pela RNA. Por sua praticidade, foi utilizado o bloco THD da ferramenta Simulink para a obtenção desse dado.

$$THD = 0,5735$$

Ao comparar com o resultado esperado, tem-se o seguinte erro percentual:

$$erro_{\%} = \frac{|0,4597 - 0,5735|}{0,4597} \cdot 100 = 24,75\%$$

## 4.2 Resultados para a Carga Não-Linear 2

A Tabela 4 apresenta os parâmetros retornados pelo algoritmo para a melhor configuração da RNA para a carga não-linear 2.

Tabela 4 - Melhor Configuração da RNA para a Carga Não-Linear 2.

<b>Número de Neurônios da Camada Intermediária 1</b>	<b>Função de Transferência da Camada Intermediária 1</b>	<b>Número de Neurônios da Camada Intermediária 2</b>	<b>Função de Transferência da Camada Intermediária 2</b>
4	logsig	4	logsig

Ao comparar a corrente obtida com a esperada, o Erro Médio Quadrático encontrado foi de:

$$MSE = 1,4096\%$$

A Figura 16 mostra a corrente retornada pela RNA após aplicar um sinal puramente senoidal na entrada. O gráfico de cima é a corrente esperada e o gráfico de baixo é a corrente retornada pela RNA. Assim como na carga não-linear 1, a rede se mostrou apta a realizar uma boa modelagem da carga em questão. A Figura 17 mostra essas correntes sobrepostas:






Figura 16 - Comparação da corrente esperada com a corrente retornada pela RNA.




Figura 17 – Correntes sobrepostas.

Para essa carga, a distorção harmônica total da corrente obtida foi de:

$$THD = 0,2082$$

Ao comparar com o resultado esperado, tem-se o seguinte erro percentual:

$$erro_{\%} = \frac{|0,1723 - 0,2082|}{0,1723} \cdot 100 = 20,71\%$$

### 4.3 Comparações com as Duas Cargas

A Tabela 5 mostra os resultados obtidos para as duas cargas não-lineares e suas respectivas comparações com os resultados esperados.

Tabela 5 – Comparações Entre as Duas Cargas.

	<b>Carga Não-Linear 1</b>	<b>Carga Não-Linear 2</b>
<b>Erro Quadrático Médio</b>	1,5118%	1,4096%
<b>DHT</b>	0,5735	0,2082
<b>Erro DHT</b>	24,75%	20,71%

### 4.4 Algumas Considerações

O sistema de modelagem apresentou um erro menor para a Carga Não-Linear 2 (resistor em série com indutor, alimentados por um retificador de onda completa). Provavelmente, isso se deve ao fato do circuito da Carga Não-Linear 2 ser mais simples (e conseqüentemente, sua forma de onda de corrente) em relação ao circuito da Carga Não-Linear 1.

Apesar de o erro quadrático médio ter sido pequeno para ambos os casos, o erro entre a DHT esperada e a DHT estimada foi relativamente alto, mostrando serem necessários estudos mais aprofundados acerca dessa relação.

Ao se deparar com erros na faixa de 20%, pode-se equivocadamente concluir que o método é ineficaz. Porém, a estimação da contribuição harmônica de cargas não-lineares utilizando redes neurais é um estudo relativamente novo, sendo comum encontrar outros trabalhos na mesma área de pesquisa apresentando erros na faixa de até 100%. Com o desenvolvimento de novas técnicas, é natural que esse erro diminua.

## 5 *Conclusões*

Esse trabalho apresentou um método que realiza a modelagem de uma carga não-linear e estima sua contribuição harmônica. Esse método auxilia em medidas corretivas por parte das concessionárias e até mesmo na aplicação de punições aos responsáveis.

Para atender a proposta do trabalho, desenvolveu-se no software MATLAB um algoritmo capaz de obter a melhor configuração de rede neural para realizar a modelagem da carga. Foram apresentados os resultados para dois tipos de cargas.

Nos dois casos, as Redes Neurais Artificiais mostraram um grande potencial para a solução do problema de estimação de contribuição harmônica, pois são capazes de representar a alta complexidade dos sinais de corrente liberadas por cargas não-lineares.

### 5.1 *Sugestões Para Trabalhos Futuros*

Sugestões para enriquecer futuros trabalhos nessa área de pesquisa:

- i. Explorar outros tipos de RNA além das Feed-Forward. Assim como outros algoritmos de treinamento.
- ii. Explorar outras técnicas de inteligência computacional, como a Lógica Fuzzy.
- iii. Simular cargas lineares mais complexas, ou até mesmo utilizar de dados reais (medidos em laboratório ou campo) para o treinamento da RNA.
- iv. Colocar impedância na linha de transmissão, filtros e transformadores.

## ***Referências Bibliográficas***

- [01] Braga, A. P., Carvalho, A. C. P. L. F., Ludermir, T. B. (2007). *Redes Neurais Artificiais, Teoria e Aplicações*. Ed LTC - 2007.
- [02] Haykin, S. (2001). *Redes Neurais, Princípios e Prática*. Ed. Bookman - 2001.
- [03] Brandão, A. S. (2006). *Redes Neurais Artificiais Aplicadas ao Reconhecimento de Comandos de Voz. Trabalho de Conclusão de Curso*. Engenharia Elétrica - Universidade Federal de Viçosa – 2006
- [04] Neves, M. V. (2009). *Uma (Breve) Introdução às Redes Neurais Artificiais. Trabalho desenvolvido na disciplina de Arquiteturas Especiais de Computadores/PPGC/UFRGS – 2009*
- [05] Barreto, J. M. (2002). *Introdução às Redes Neurais Artificiais*. Disponível em <http://www.inf.ufsc.br/~barreto/tutoriais/Survey.pdf>
- [06] Karayinnis, N. B., Venetsanopoulos, A. N. (1992). *Artificial Neural Networks: Learning Algorithms, Performance Evaluation and Applications*. Ed Kluwer Academic - 1992.
- [07] Dodonov, E., Mello, R. F. (2008) *Estudo sobre abordagens de extração, classificação e predição de comportamento de processos*.
- [08] Silva, L. R. M. (2012). *Inteligência computacional aplicada à modelagem de cargas não-lineares e estimação de contribuição harmônica*. Dissertação (Mestrado em Engenharia Elétrica) - Universidade Federal de Juiz de Fora, 2012.
- [09] Junior, G. V. A. (2007). *Estimação da Contribuição Harmônica de Tensão em Sistemas Elétricos Trifásicos*. Dissertação (Mestrado em Engenharia Elétrica) - Universidade Federal de Campina Grande, 2007.
- [10] Dugan, R. C., McGranaghan, M. F., Santoso, S., Beaty, H. W. (2003). *Electrical Power Systems Quality*. Ed McGraw Hill, 2003.
- [11] Dias, G. (2002). *Harmônicas em Sistemas Industriais*. Ed Edipucrs, 2002.
- [12] W. Xu and Y. Liu. (2000) “A Method for Determining Customer and Utility Harmonic Contributions at the Point of Common Coupling,” *IEEE Transactions on Power Delivery*, vol. 15, no. 2, pp. 804–811, Abril 2000.
- [13] J. Mazumdar and R. G. Harley (2008) “Recurrent Neural Networks Trained With Backpropagation Through Time Algorithm to Estimate Nonlinear Load Harmonic Currents,” *IEEE Transactions on Industrial Electronics*, vol. 55, no. 9, pp. 3844–3491, Setembro 2008.
- [14] G. Cybenko. (1989) *Approximation by superpositions of a sigmoid function*. *Mathematics of Control, Signals and Systems*, 2:303-314, 1989
- [15] IEEE-STD.519. *Recommended Practice and Requirements for Harmonic Control in Electric Power Systems*. [S.I.], 1992.