



UNIVERSIDADE FEDERAL DE CAMPINA GRANDE  
CENTRO DE ENGENHARIA ELÉTRICA E INFORMÁTICA  
UNIDADE ACADÊMICA DE ENGENHARIA ELÉTRICA



IGOR DE SOUSA MEDEIROS TORRES

TRABALHO DE CONCLUSÃO DE CURSO

Análise de Padrões de Descargas Parciais Por Uma Rede Neural Artificial

Campina Grande

Outubro de 2012

IGOR DE SOUSA MEDEIROS TORRES

TRABALHO DE CONCLUSÃO DE CURSO

*Trabalho de Conclusão de Curso submetido à  
Unidade Acadêmica de Engenharia Elétrica da  
Universidade Federal de Campina Grande como parte  
dos requisitos necessários para a obtenção do grau de  
Bacharel em Engenharia Elétrica.*

Aprovado em     /     /

Igor de Sousa Medeiros Torres  
Aluno

Professor Avaliador  
Universidade Federal de Campina Grande

Edson Guedes da Costa, Dr. Sc.  
Universidade Federal de Campina Grande

*Dedico este trabalho aos meus pais,  
pois sem eles jamais chegaria até aqui.*

## Agradecimentos

---

Agradeço primeiramente a meus pais, Geni de Sousa Medeiros Torres e José de Medeiros Torres, pelo incontestável suporte durante toda minha vida, seja materialmente ou afetuosamente.

Às minhas irmãs, Camila e Isabelle, pelo apoio e paciência jamais negados ao longo da minha vida.

Aos meus tios e primos, como Newton Fonsêca, pela assistência e companheirismo durante essa jornada.

Ao Laboratório de Alta Tensão (LAT) por permitir o uso de suas instalações.

Ao meu Professor Edson Guedes da Costa, pela orientação não somente durante o meu estágio, mas também durante minha vida acadêmica, sempre me oferecendo oportunidades para aprofundar meus estudos e experiência através de projetos de P&D.

Ao Professor Euler Cássio Tavares de Macêdo (UFPb), pelo direcionamento, suporte, ideias e auxílio nas atividades do estágio, como o fornecimento das amostras e célula de teste, que tanto ajudaram a engrandecer essa experiência.

Aos professores do Departamento de Engenharia Elétrica (DEE) da Universidade Federal de Campina Grande (UFCG) que contribuíram, sempre de forma prestativa, para a construção do conhecimento que hoje possuo.

Aos funcionários do DEE, especialmente os do LAT, que foram peças fundamentais para o sucesso da realização das atividades pertinentes ao trabalho e à minha graduação.

E a todos os inestimáveis amigos que fiz durante a graduação.

## Resumo

Os isoladores são equipamentos essenciais ao funcionamento do sistema elétrico. São responsáveis pela separação de partes vivas com potenciais neutros e evitam a circulação de correntes indesejadas. Quando falham, a repercussão do problema pode ser gravíssima, levando à desenergização de linhas e conseqüentemente de cidades, comprometendo a economia, a segurança e até mesmo a vida dos usuários da rede elétrica.

Os isoladores elétricos podem ser de três tipos: porcelana, vidro e poliméricos. Este último está em plena expansão devido ao seu custo reduzido e boa confiabilidade. Entretanto esses equipamentos sofrem com o ataque das descargas parciais quando submetidos a campos elétricos elevados. Essas descargas surgem e desaparecem instantaneamente em cavidades preenchidas de ar que encontram-se inadvertidamente nesses equipamentos devido a falhas intrínsecas ao processo de fabricação. A ação contínua das descargas parciais levam à carbonização do polímero, criando um caminho preferencial de circulação de corrente, podendo culminar na falha da isolação e comprometimento do sistema.

Este trabalho propõe a análise de padrões de descargas parciais devido à geometria, posicionamento e quantidade desses defeitos no isolamento, buscando provar que é possível a detecção desse problema através do sinal dessas descargas. Para tal utilizam-se as Redes Neurais Artificiais, que são algoritmos computacionais de reconhecimento e classificação de padrões em problemas que aparentemente não existe uma relação simples entre as diversas variáveis envolvidas.

## Abstract

Insulators are a fundamental equipment for electrical power systems. They carry the responsibility of separating live parts from the neutral potential and avoid unwanted current circulation. When they fail, the repercussion of the problem could be extreme, carrying out to de-energizing lines and, ultimately cities, compromising the economy, public security and even the lives of the power grid users.

There are three kinds of electrical insulators: porcelain, glass and polymeric. The ladder is in full expansion due to its reduced costs and good reliability. However, these equipments suffer the attacks of partial discharges when subjected to high electric fields. These discharges appear and disappear instantaneously in voids filled with air that are inadvertently in these equipments due to flaws of the construction process. The continuous action of these discharges leads to carbonization of the polymer, creating a favorable path for current circulation, culmination in insulation flaw and system breakdown.

This work proposes the analysis of partial discharges patterns due to geometry, positioning and quantity of these insulation flaws, seeking to prove that the detection of this problem it is possible through the signals emitted by these discharges. For this, Artificial Neural Networks, which are computer algorithms for pattern recognition and classification, are used in problems that apparently don't have a simple relationship between the numerous variables involved.

## Lista de Figuras

Figura 1 - Esquema de ocorrência de descarga parcial em conexão flutuante .....	13
Figura 2 - Esquema do interior de um isolador polimérico com cavidade .....	14
Figura 3 - Distribuição de Campo Elétrico em Isolador Polimérico com Bolha de 1 mm de raio .....	15
Figura 4 - Modelo de um neurônio numa RNA.....	18
Figura 5 - Amostras de fenolite perfuradas .....	22
Figura 6 - Célula de Teste - Esquemático.....	24
Figura 7 - Célula de Teste.....	24
Figura 8 - Célula de teste preenchida com óleo de transformador, acoplado a uma seringa.....	25
Figura 9 - Kit de Alta Tensão do LAT-UFCG .....	25
Figura 10 - Notebook, rodando o software LDS-6®, sobre o LDIC®.....	26
Figura 11 - Wizard do toolbox de reconhecimento de padrões por RNA do MATLAB® .....	27
Figura 12 - Arranjo de para Medição de Descargas Parciais .....	28
Figura 13 - Montagem do circuito de medição em laboratório. CT é a célula de teste, representada por Ca no esquemático da figura anterior e CD é o $Z_{mi}$ [10] .....	29
Figura 14 - Imagem obtida do programa LDS-6 durante a medição de DP [10] .....	30
Figura 15 - Resultado da medição antes da filtragem .....	30
Figura 16 - Dados após filtragem .....	31
Figura 17 - Wizard do Matlab de RNAs: Seleção da quantidade de neurônios. Nesse caso, com todas as pastilhas sob análise e 32 neurônios na camada oculta .....	34
Figura 18 - Tela pós-solução. %E indica a porcentagem de erro nas etapas de solução	34
Figura 19 - Erro médio quadrático .....	35
Figura 20 - Porcentagem de acerto da RNA por quantidade de pastilhas de fenolite analisadas.....	36

## Lista de Tabelas

Tabela 1 – Posicionamento dos Defeitos nas Amostras de Fenolite .....	19
Tabela 2 .....	32

## Sumário

Agradecimentos .....	4
1 – Introdução .....	10
2 – Fundamentação Teórica.....	11
2.1 – Isoladores.....	11
2.2 – Descargas Parciais .....	12
2.2.1 - Introdução.....	12
2.2.2 – Mecanismo de Ocorrência de Descargas Parciais .....	13
2.3 – Redes Neurais Artificiais.....	17
2.3.1 – Introdução.....	17
2.3.2 – O bloco básico das RNA: O neurônio .....	18
2.3.4 – Treinamento, Validação e Teste: As etapas de configuração de uma RNA	19
2.3.5 – Aquisição de Parâmetros .....	20
3 – Materiais e Métodos .....	21
3.1 – Materiais .....	21
3.1.1 – Amostras de Fenolite .....	21
3.1.2 – Equipamentos de Laboratório.....	25
3.1.3 – Software.....	26
3.2 – Métodos .....	27
3.2.1 - Ensaio .....	28
3.2.2 – Tratamento dos Dados .....	30
3.2.3 – Extração de Atributos .....	31
4 – Resultados.....	33
5 – Conclusões.....	37
6 – Referências Bibliográficas.....	38
7 – Anexo.....	39
7.1 - Código em linguagem Matlab® para extração de atributos do sinal de descargas parciais.....	39

## 1 – Introdução

As Descargas Parciais (DP) se caracterizam por pulsos de corrente de alta frequência que ocorrem no interior dos equipamentos elétricos de alta tensão, e são originadas pelo processo de ionização do meio gasoso submetido a um elevado campo elétrico [1]. Esse meio gasoso se encontra no interior do meio dielétrico e decorre principalmente de erros de fabricação inerentes ao processo industrial de criação dos equipamentos destinados à isolação no sistema elétrico.

Os isoladores são os dispositivos responsáveis pela isolação entre as partes vivas e a terra, podendo ser construídos à base de cerâmica, vidro ou polímeros. Nos primórdios dos sistemas elétricos não havia grande preocupação com o fenômeno das descargas parciais visto que não comprometiam a capacidade de isolamento dos primeiros isoladores instalados nas linhas de transmissão e distribuição de energia elétrica. Entretanto, com o advento dos isoladores poliméricos, que são mais susceptíveis a esse tipo de agressão, o estudo dessas descargas vem ganhando cada vez mais importância nos meios acadêmicos.

Com efeito, a diretriz de se estudar as descargas parciais faz parte deste trabalho. Tem-se por objetivo a avaliação da classificação de padrões de configuração de defeitos por Redes Neurais Artificiais (RNA), que são algoritmos especializados no reconhecimento de padrões. Tal estudo é importante já que será possível avaliar a previsibilidade de certas configurações para a ocorrência de descargas e sua possibilidade de classificação por intermédio de um software.

Neste trabalho será feita a revisão bibliográfica acerca do tema das Descargas Parciais, Isoladores Elétricos e Redes Neurais Artificiais. Em seguida será descrito o método de ensaio e detalhamento das amostras e invólucros utilizados nos ensaios de alta tensão para coleta de dados e também um detalhamento do posterior pré-processamento computacional, seguido dos resultados obtidos.

## **2 – Fundamentação Teórica**

Um estudo sobre descargas parciais não pode deixar de citar informações sobre seus mecanismos de criação e como podem comprometer o isolamento. Isolamento esse que deve ser também explicado em termos da sua aplicação no sistema elétrico como um todo. Além disso, os dados tratados nesse trabalho utilizaram as Redes Neurais Artificiais como algoritmo computacional para a separação e identificação dos padrões de descargas.

### **2.1 – Isoladores**

Os isolantes são componentes que têm como função evitar a circulação de cargas elétricas entre pontos com potenciais elétricos diferentes. Para alcançar esse objetivo, um isolador deve atender dois requisitos: deve possuir resistência elétrica e uma constante dielétrica suficientemente altas para a aplicação desejada. Os requisitos secundários são relacionados às propriedades térmicas e mecânicas. Ocasionalmente, características terciárias são observadas como as perdas no dielétrico. Isolantes podem ser sólidos ou líquidos [2].

Isolantes sólidos flexíveis podem ser resinas termoplásticas de carbono e isolamento à base de papel celulose. Já os isolantes rígidos, os isoladores elétricos, largamente empregados nos sistemas elétricos para sustentação de condutores, incluem o vidro, mica, epóxis e outros polímeros, alumina e outras cerâmicas. Além de serem usados como isolamento para fios e cabos, esses materiais são empregados em terminais de equipamentos (como buchas) e como suportes isolantes (tensionados ou comprimidos) para linhas aéreas cujo dielétrico primário é o ar. Essas estruturas devem ser resistentes ao choque, relativamente hidrofóbicas e capazes de suportar descargas corona sobre sua superfície. [2]

Apesar dos isoladores poliméricos serem um produto relativamente novo, eles capturaram cerca de 20% do mercado americano de linhas de transmissão e essa fatia de mercado só tende a crescer. Eles representam a maior mudança em design de isoladores

em muitos anos e suas vantagens sobre isoladores de vidro e porcelana os tornaram atraentes às empresas do setor elétrico. Sua vida útil ainda é um mistério, em contraste com isoladores de vidro e de porcelana que tem uma longa expectativa de vida em serviço [3]. As vantagens comparadas aos isoladores de porcelana são:

- Peso leve - Menor custo de transporte e construção;
- Resistência ao vandalismo - Menos danos resultantes de projéteis balísticos;
- Alta razão força/peso - cadeias maiores/novos designs de torre;
- Melhor desempenho sob poluição;
- Estética das linhas de transmissão melhoradas. [3]

## **2.2 – Descargas Parciais**

### **2.2.1 - Introdução**

Descargas Parciais (DP) podem ser geradas por muitos fenômenos. De um ponto de vista prático, descargas parciais ocorrem quando alguma forma de atividade elétrica dentro de um sistema resulta em uma rápida mudança na configuração de campo elétrico, o que causa um fluxo de corrente em um condutor conectado ao mundo exterior. Para ser reconhecida como DP, a corrente induzida no condutor externo deve ser suficientemente grande para ser detectada e deve ocorrer com uma repetição suficiente para ser reconhecida como algo mais além de ruído aleatório. [4]. Isso não é realidade para a maioria das descargas que ocorrem no interior de meios dielétricos e por isso a detecção e medição de descargas parciais é um processo difícil e trabalhoso. As fontes mais comuns de descargas parciais são conexões flutuantes, corona e cavidades.

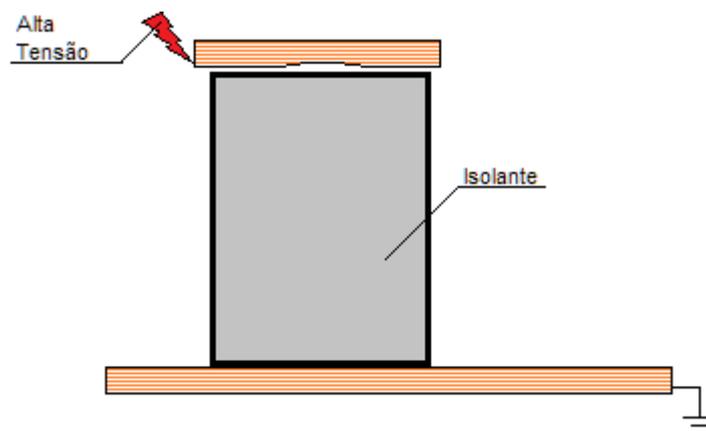


Figura 1 - Esquema de ocorrência de descarga parcial em conexão flutuante

Em caso de conexões as descargas se dão principalmente pela modificação da capacitância no pequeno achatamento, como pode ser observado na Fig. 1. As distribuições das tensões se dão principalmente devido à adequação do campo elétrico a essas capacitâncias equivalentes em decorrência da estrutura do equipamento. Em razão dessa desconformidade, o campo elétrico se distorce e torna-se mais intenso em certas áreas no espaçamento.

### 2.2.2 - Mecanismo de Ocorrência de Descargas Parciais

Descargas Parciais, quando ocorrem em pequenas cavidades, podem assumir diferentes formas: com rápido e lento tempo de subida em pulsos tipo centelhamento, brilhos sem pulso reais ou descargas com um pseudo-brilho. Todas essas formas de emissão são descargas sustentadas-por-emissão do catodo, isto é, são essencialmente descargas de Townsend em contradição com descargas de mecanismo de canal cujas características são a independência da emissão do catodo e sua dependência de fotoionização do gás no volume. [5]

Os meios de ocorrência dessas descargas se dão principalmente devido a defeitos de fabricação em isolantes empregados nos equipamentos do sistema elétrico que têm por função prevenir a circulação de corrente entre as partes vivas e o potencial nulo da terra. Dependendo do ambiente em que está imersa a descarga, esta pode ser extremamente prejudicial para o bom funcionamento do equipamento, considerando que este ficará em operação durante anos.

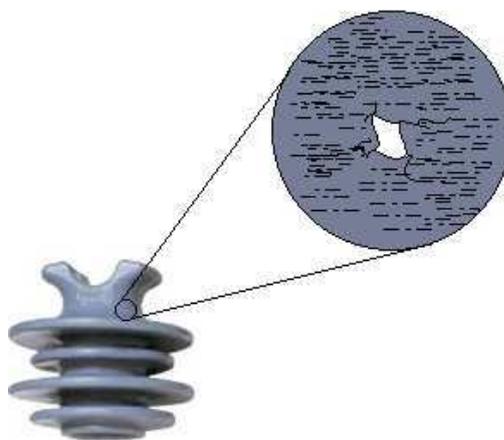


Figura 2 - Esquema do interior de um isolador polimérico com cavidade

Suponha que durante o processo de fabricação do isolador polimérico tipo pino acima, durante o preenchimento do molde com a resina polimérica da sua constituição, minúsculas cavidades de ar formara-se ao fim do processo de enchimento e, devido ao tamanho reduzido do defeito, sua detecção não foi possível ao cabo do processo industrial, visto que o equipamento é feito em lotes e apenas poucas amostras são testadas. Tal suposição não é nenhuma suposição difícil de conceber, já que o sistema de fabricação desses componentes não é infalível e esse tipo de falha ocorre com certa frequência.

Quando o isolador for empregado em serviço, essa pequena cavidade preenchida de ar, ao ser submetida a um campo elétrico de alta intensidade, ao depender do nível dessa intensidade, pode ter sua rigidez dielétrica rompida momentaneamente. Como a distância é muito curta e a circulação de corrente é dificultada pela resistência que é criada pelo próprio material polimérico, essa pequena descarga elétrica não é capaz de se sustentar e cessa instantes depois de sua criação. Daí o nome descarga parcial. O gráfico abaixo representa a distribuição de tensão em um isolador tipo pino, onde, aproximadamente entre 2 e 4 mm de distância do condutor, energizado a 13.8 kV, existe uma bolha de ar de 1 mm de raio. Nota-se uma grande elevação do potencial na região da bolha. O gráfico foi produzido com o auxílio do software de simulação de campos elétricos Comsol Multiphysics®.

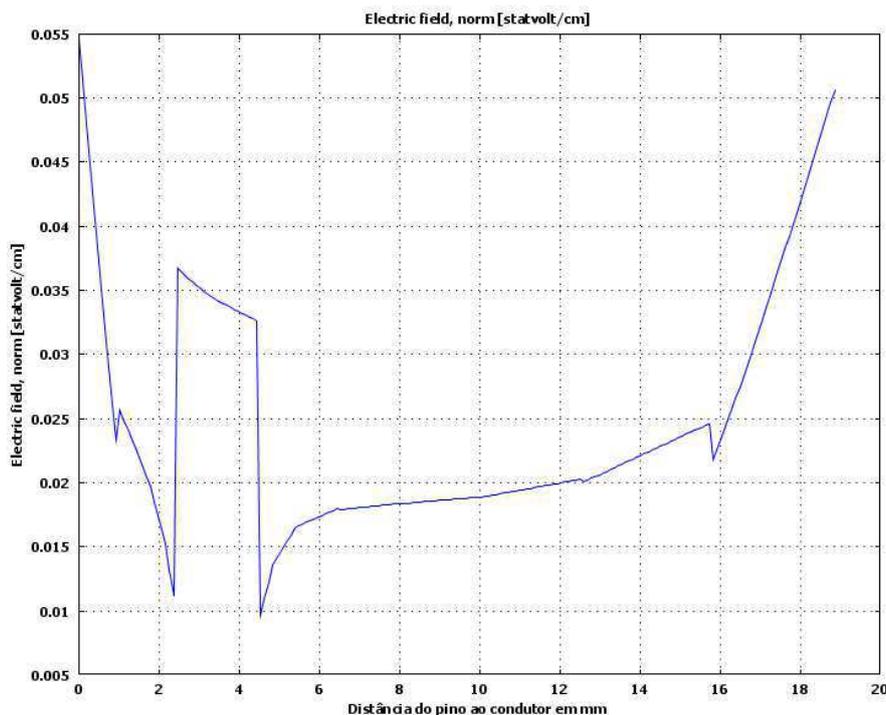


Figura 3 - Distribuição de Campo Elétrico em Isolador Polimérico com Bolha de 1 mm de raio

Esse mecanismo de descarga em pequenas distâncias é explicado por John Sealy Townsend, e leva seu nome. Na ausência de campo elétrico a taxa de geração de elétrons e íons positivos em um gás ordinário é contrabalanceada pelo processo de decaimento e estado de equilíbrio existente. Esse equilíbrio é perturbado pela aplicação de um campo elétrico suficientemente alto. Townsend descobriu que a corrente aumenta primeiramente de maneira proporcional à tensão aplicada e mantinha-se relativamente constante a um valor  $i_0$  que corresponderia à corrente de saturação. Com o crescimento do campo, os elétrons deixando o catodo são acelerados cada vez mais entre as colisões até que ganhem energia suficiente para causar ionização na colisão com as moléculas ou átomos de gás. Outros processos responsáveis por elevar ainda mais a curva de corrente durante a ruptura dielétrica no gás e incluem a emissão secundária de elétrons no catodo por impacto de fótons e a fotoionização do próprio gás. Na prática, ambos os íons positivos e fótons podem estar ativos ao mesmo tempo na produção secundária de elétrons no catodo. Além disso, átomos metastáticos podem contribuir para o mecanismo secundário. [6]

O dano causado ao equipamento depende do material empregado na isolação. Existem materiais mais susceptíveis em que a energia decorrente dessa descarga é suficiente para quebrar a estrutura da matéria, transformando o material em contato com a descarga parcial. No caso dos isoladores constituídos de vidro e porcelana, a estrutura

desses materiais é extremamente estável e coesa, e um nível de energia absurdamente elevado é necessário para modificar a estrutura dessa matéria. Portanto, as descargas parciais ocorrem continuamente em isoladores de vidro e porcelana, mas são inofensivas a esses equipamentos, pois não há comprometimento da isolação elétrica, mesmo após dezenas de anos em serviço.

O mesmo não pode ser dito dos isoladores poliméricos. A energia liberada na descarga parcial pode ser capaz de comprometer as ligações dos átomos das moléculas cuja base é o carbono. Dessa forma, ocorre uma queima e uma consequente carbonização no local onde ocorre a descarga parcial. Com o tempo, essa carbonização pode crescer devido às sucessivas descargas ocorrendo no mesmo local, e acaba criando um caminho preferencial de circulação de corrente, levando, eventualmente ao comprometimento da isolação e falha do equipamento.

A falha de um equipamento, como um isolador ou cadeia de isoladores poliméricos, no sistema elétrico, é causa de desligamentos que possam ocorrer na rede. Esses desligamentos não previstos geram grandes prejuízos para as empresas de geração, transmissão e distribuição de energia, pois a falha no isolamento leva à atuação da proteção e a consequente desenergização de linhas e cargas. Além de cessar a venda de energia, a interrupção no serviço ocasiona pesadas multas por parte da Agência Nacional de Energia Elétrica, que regula o setor elétrico brasileiro, como punição pela cessação de prestação de serviço.

Dessa forma, o estudo e compreensão das descargas parciais é vital para entender sua ação sob os equipamentos do sistema elétrico e assim, tornar possível a adoção de medidas preventivas ao invés de corretivas, evitando prejuízos e inconvenientes para os operadores e usuários do sistema.

## 2.3 – Redes Neurais Artificiais

As Redes Neurais Artificiais (RNA) são algoritmos computacionais que apresentam as melhores performances quando são empregados na classificação de padrões que, através de uma base de dados que servem de parâmetro, são capazes de distinguir entre classes diversas.

Por seu notável desempenho na classificação de padrões, o emprego de RNAs para separar sinais de descargas parciais mostra-se extremamente conveniente para o propósito deste trabalho.

### 2.3.1 – Introdução

O início do interesse pela pesquisa em RNAs começou na década de 1940 e se deu utilizando circuitos elétricos baseados em arquiteturas biológicas de neurônios de forma a realizarem trabalhos computacionais. Entretanto, após a publicação do livro *Perceptrons* em 1969 por Minsky e Papert, que mostravam as deficiências nos modelo e direcionamento das pesquisas até então, houve uma fuga de cientistas que trabalhavam na área.

O aumento de poder de processamento computacional e novas descobertas de alguns pesquisadores que se mantiveram na área reacendeu o interesse pelas RNAs no começo dos anos 80 e hoje em dia é objeto de interesse dos mais variados grupos de pesquisa em várias universidades ao redor do mundo.

Redes Neurais Artificiais podem ser mais adequadamente caracterizadas como 'modelos computacionais' com propriedades particulares tais como a habilidade de adaptar-se e aprender, generalizar, agrupar ou organizar dados e na qual a operação é baseada em processamento paralelo. Entretanto, muitas das características mencionadas acima podem ser atribuídas a modelos 'não-neurais' existentes; a questão mais intrigante é até que nível a abordagem neural apresenta-se mais adequada para certas aplicações do que os modelos existentes. Até hoje não existe uma resposta para essa pergunta. [7]

### 2.3.2 - O bloco básico das RNAs: O neurônio

Corroborando a visão inicial de uma rede neural biológica, a unidade fundamental básica de uma RNA é o neurônio, cujo modelo é apresentado na figura abaixo.

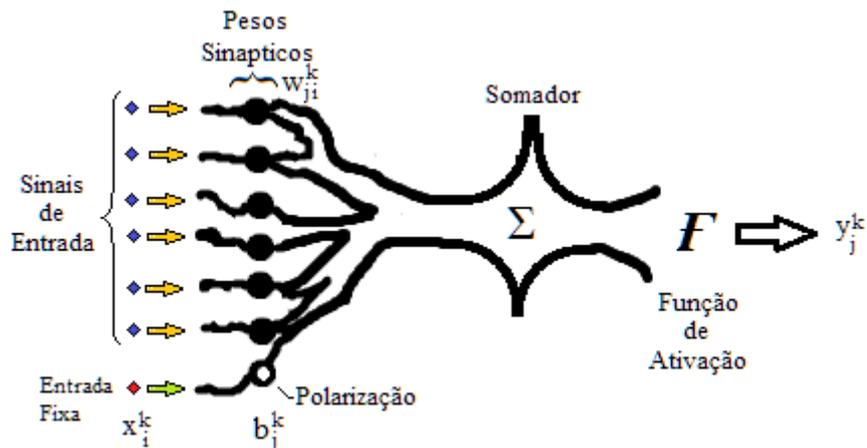


Figura 4 - Modelo de um neurônio numa RNA

Existem três elementos fundamentais na estrutura do neurônio [8]:

- Um conjunto de sinapses ou conexões, caracterizadas individualmente por um peso sináptico  $w_{ji}^k$ , que indica a importância do sinal de entrada  $i$  na determinação da saída do neurônio  $j$  da camada  $k$ .
- Um somador, que tem a função de realizar uma combinação linear dos sinais de entrada ponderada pelos respectivos pesos sinápticos de suas ligações.
- Uma função de ativação  $F_j^k$ , que limita a amplitude da saída a um intervalo normalizado, geralmente  $[0,1]$  ou  $[-1,1]$ .

O modelo do neurônio também inclui um termo denominado de polarização representado por  $b_j^k$ , cujo efeito é modificar a entrada da função de ativação, através da aplicação de um sinal de entrada com valor fixo em +1.

Matematicamente, a saída do neurônio  $y_j^k$  é representado pela seguinte equação:

$$y_j^k = F_j^k(b_j^k + \sum_{i=1}^{I^k} w_{ij}^k x_i^k)$$

onde  $I^k$  representa o número de entradas da camada. A função  $F$  é geralmente uma função sigmoidal, a exemplo da tangente hiperbólica.

Uma camada é formada por um conjunto de neurônios que formam o corpo da rede. Após passar por cada neurônio, as saídas destes tornam-se entradas para neurônios de uma camada subsequente e assim por diante até a saída final, que terá como resultado a classificação os dados de entrada em classes definidas.

#### **2.3.4 - Treinamento, Validação e Teste: As etapas de configuração de uma RNA**

Após uma rede neural ter sido criada, ela precisa ser configurada e então treinada. Configuração envolve manipulação da rede para que ela seja compatível com o problema que você deseja resolver, como é definido pelos dados das amostras. Depois de a rede ter sido configurada, o ajuste dos parâmetros da rede, chamados de pesos e biases, precisam ser ajustados, de forma que a performance da rede seja otimizada. Esse processo de ajuste é conhecido como o treinamento da rede. Configuração e treinamento da rede requerem que ela seja provida de dados que sirvam de exemplo. [9]

Dessa forma, os procedimentos que fazem parte das etapas de configuração da RNA com aprendizado supervisionado são os seguintes:

- **Treinamento:** Nesse processo, os pesos das entradas das sinapses neurais são inicializados com valores aleatórios e a rede então interage. Sabendo-se o resultado esperado da base de dados de entrada, calcula-se então um erro que é realimentado à rede. Dependendo do processo de treinamento, se é de alimentação direta (no qual os dados seguem um fluxo contínuo da entrada para saída) ou com retroalimentação (onde os dados seguem em direção à saída e retornam com o erro corrigindo a rede de trás para frente), a rede corrige-se a partir do cálculo de um erro que é alimentado nas sinapses na interação seguinte. Essas interações são chamadas de épocas. É no treinamento que ocorre a aprendizagem da rede neural.
- **Validação:** Nesta etapa a rede avalia o desempenho do processo de aprendizagem e generalização, para que seja certificado que ela está aprendendo a classificar as classes desejadas e não 'decorando' padrões, tornando-se incapaz

de classificar corretamente dados que sejam levemente diferentes da base mais comum de dados da classe desejada.

- Teste: Nessa fase final, que só ocorre após o treinamento e a validação, a RNA está pronta para ser utilizada e são empregados dados de entrada previamente separados para certificar de que a rede possua uma boa taxa de acerto a partir de informações de parâmetros de entrada.

Ainda existem redes capazes de separar dados em classes sem um conjunto definido de entradas e saídas. São as redes não-supervisionadas. Elas agrupam conjuntos de dados em classes que possuem características semelhantes e não necessitam de um vetor de saída indicando as saídas esperadas, a ser utilizado no processo de treinamento. Esse processo é conhecido por clusterização (do inglês *cluster* = aglomerar).

### **2.3.5 – Aquisição de Parâmetros**

Para resolver um determinado problema através de uma RNA, faz-se necessário que a mesma possua uma base de dados sólida e bem desenvolvida e que, principalmente, possua informações relevantes sob os aspectos únicos de cada classe a ser identificada pelo algoritmo.

Esse é um passo primordial e que deve ser realizado antes da configuração da RNA. Essa aquisição de parâmetros nada mais é que a extração de informações que servirão de entrada para cada neurônio e sua qualidade é determinante para o sucesso da rede. Por exemplo, deseja-se classificar de qual vinícola um conjunto de amostras de vinho vieram. Para tal, é fornecida à rede uma série de informações, de um conjunto de amostras extraídas de 180 garrafas de vinho. Cada uma dessas amostras possui 10 parâmetros, como teor alcoólico, alcalinidade, teor de magnésio, intensidade da cor, teor de fenóis, etc. Sabe-se que esses vinhos vieram de três vinícolas diferentes do Brasil. Logo, à partir das informações de entrada, a RNA será capaz de classificar, com uma pequena margem de erro, a qual vinícola pertence uma determinada amostra aleatória de vinho.

### 3 – Materiais e Métodos

Para obter informações de descargas parciais para servirem de parâmetros para uma RNA é preciso primeiro obter esses sinais de descarga. Para tal, amostras e um receptáculo apropriado foram criados de maneira que fosse possível realizar ensaios de alta tensão sob as normas internacionais vigentes para obtenção desse tipo de informação.

#### 3.1 – Materiais

##### 3.1.1 – Amostras de Fenolite

Foram confeccionadas 10 amostras de fenolite, agrupadas em discos de 28 mm de diâmetro e 1.6 mm de espessura. Essas amostras foram perfuradas com furos de 1 e 2 mm e posteriormente coladas. Cada amostra possui um número distinto de furos em posições diferentes.



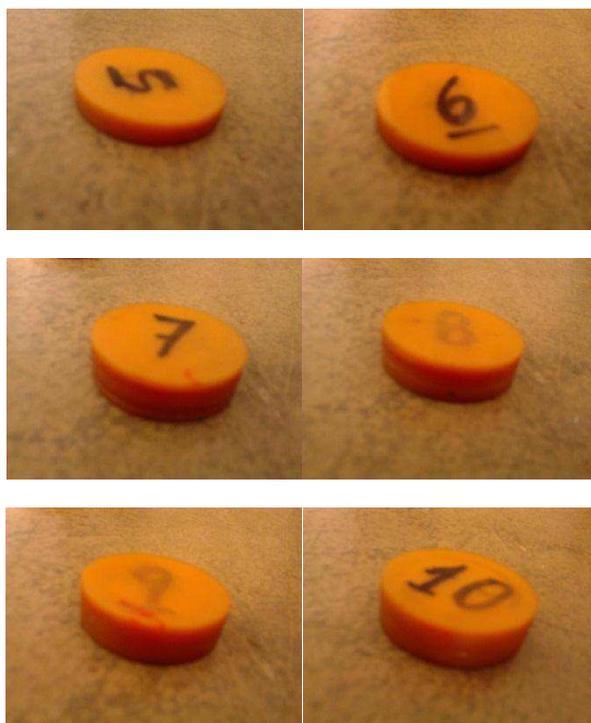


Figura 5 - Amostras de fenolite perfuradas

A tabela a seguir detalha as configurações das simulações de defeitos que foram introduzidas nas amostras de fenolite. A ideia é criar cavidades propositais que se espelham nos defeitos de fabricação de isoladores poliméricos por implantar furos nas pastilhas de fenolite. Existem amostras com três e quatro camadas de pastilhas, naturalmente com a última possuindo uma altura maior devido ao empilhamento dessas placas.

Tabela 1 – Posicionamento dos Defeitos nas Amostras de Fenolite [10]

Amostra	Diâmetro da cavidade (mm)	Posicionamento das cavidades
1	2	
2	1	
3	2	
4	1	
5	2	
6	1	
7	2	
8	1	
9	2	
10	1	

Para que fosse possível a aplicação da alta tensão nas pastilhas de fenolite, foi necessário utilizar uma Célula de Teste que fosse compatível com a dimensão das amostras e fosse capaz de proporcionar um bom nível de isolamento. Dessa forma, empregou-se o equipamento abaixo, desenvolvido pelo aluno de doutorado da UFCG, Euler Macêdo.

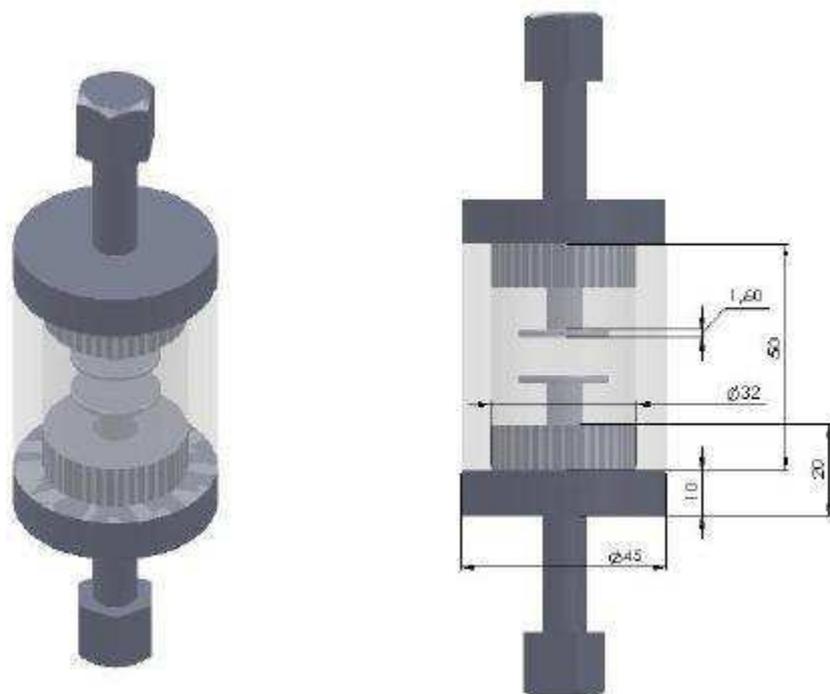


Figura 6 - Célula de Teste – Esquemático [10]

A célula de teste, construída em acrílico, PVC e cobre, possui ainda orifícios para a inserção e retirada de óleo de transformador, que foi empregado como meio isolante para evitar o surgimento de descargas fora das pastilhas de fenolite.



Figura 7 - Célula de Teste

A distância entre os eletrodos é variável para que a amostra possa se acomodar de acordo com a necessidade de tamanho para cada caso.



Figura 8 - Célula de teste preenchida com óleo de transformador, acoplado a uma seringa

### 3.1.2 - Equipamentos de Laboratório

As amostras de fenolite, inseridas na célula de teste, foram testadas nas dependências do Laboratório de Alta Tensão (LAT), da UFCG, no Kit de Alta Tensão, que dispõe de transformador para experimentos com tensão de saída no secundário na faixa de 0 a 100 kV, a uma potência de 5 kVA, para uma entrada de 0 a 220 V. Essa entrada é controlada em uma mesa reguladora que possui um regulador de tensão capaz de modificar essa tensão de entrada na faixa desejada.



Figura 9 - Kit de Alta Tensão do LAT-UFCG

Para a detecção das descargas parciais, foi utilizado um equipamento comercial detector de DPs existente no LAT, o LDIC® da Lemke®. Esse equipamento detecta uma largura de banda entre 100 kHz e 1000 kHz, para sinais que representem uma carga entre 1 pC até 100.000 pC. O sinal de DP sai do LDIC® e, através de uma conexão de rede, é recebido por um *notebook* com o *software* LDS-6® instalado. Esse software, do próprio fabricante do LDIC® é o responsável por coletar e organizar os dados relativos às descargas parciais, proveniente do equipamento detector.

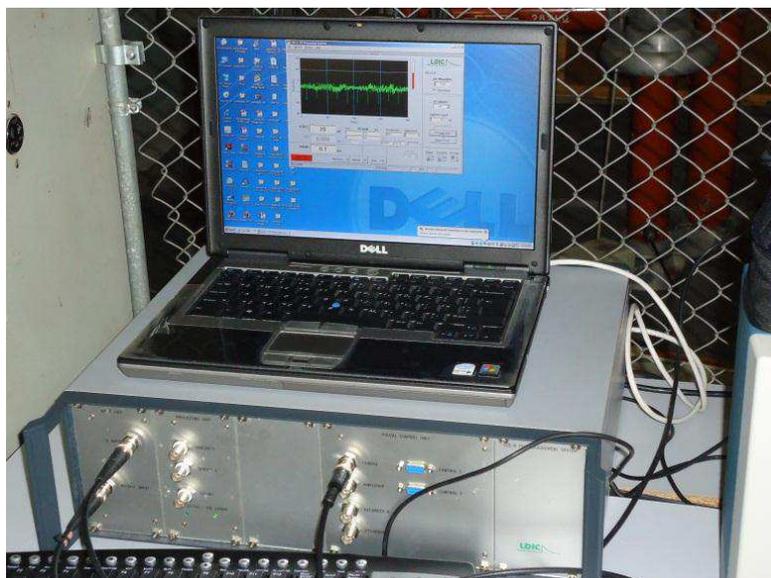


Figura 10 - Notebook, rodando o software LDS-6®, sobre o LDIC®

Outros equipamentos auxiliares na montagem do ensaio de detecção de DPs são o capacitor de acoplamento, impedor, filtro, resistência de 270 k $\Omega$ , divisor capacitivo, cabos e barras condutoras, além de um gerador de sinais de descargas parciais com propósitos de calibração do instrumento detector.

### 3.1.3 - Software

A aquisição dos dados foi feita por intermédio do software LDS-6® da Lemke®, que obteve os dados referentes à intensidade dos níveis de descargas parciais detectadas pelo LDIC®. Esse software pode ser conferido na Fig. 10.

Os dados obtidos por intermédio do LDS-6® foram tratados usando o *Matrix Laboratory*, ou como é popularmente conhecido, MATLAB®. Para extração de

atributos foi escrito um código em MATLAB para que as informações que alimentarão a rede neural sejam obtidas. Esse código encontra-se na seção de Anexos deste trabalho.

Além disso, para implementação da Rede Neural Artificial, foi utilizado também o MATLAB®, particularmente o *toolbox Neural Network Pattern Recognition Tool 6.0.4 (R2010a)* (em português: Ferramenta de Reconhecimento de Padrões em Redes Neurais). Esse software implementa uma RNA do tipo *perceptron*, de duas camadas, com a quantidade de neurônios a ser definida pelo usuário. É possível também definir a porcentagem de dados de entrada que serão utilizados nas etapas de treinamento, validação e teste. Os resultados mostrados enaltecem a porcentagem de erro na classificação feita pela rede neural no momento do teste, após as etapas anteriores de processamento terem sido concluídas.

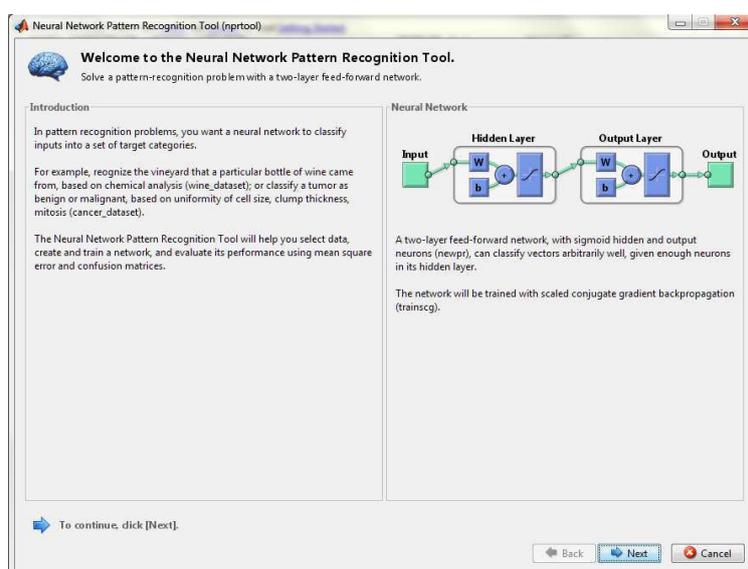


Figura 11 - Wizard do toolbox de reconhecimento de padrões por RNA do MATLAB®

### 3.2 – Métodos

A metodologia de ensaio foi repetida para todas as amostras em todos os casos estudados e todas as amostras foram ensaiadas no mesmo nível de tensão para garantir que os resultados de uma mesma amostra apresentem semelhança e confiabilidade em suas medições. Da mesma forma foi o procedimento para o tratamento dos dados de entrada da Rede Neural Artificial.

### 3.2.1 - Ensaio

O ensaio de descargas parciais foi feito com obediência à norma IEC 60270, cujo título é High-Voltage Test Techniques – Partial Discharge Measurements (em português: Técnicas de Teste em Alta Tensão – Medição de Descargas Parciais). O arranjo montado pode ser conferido na montagem abaixo.

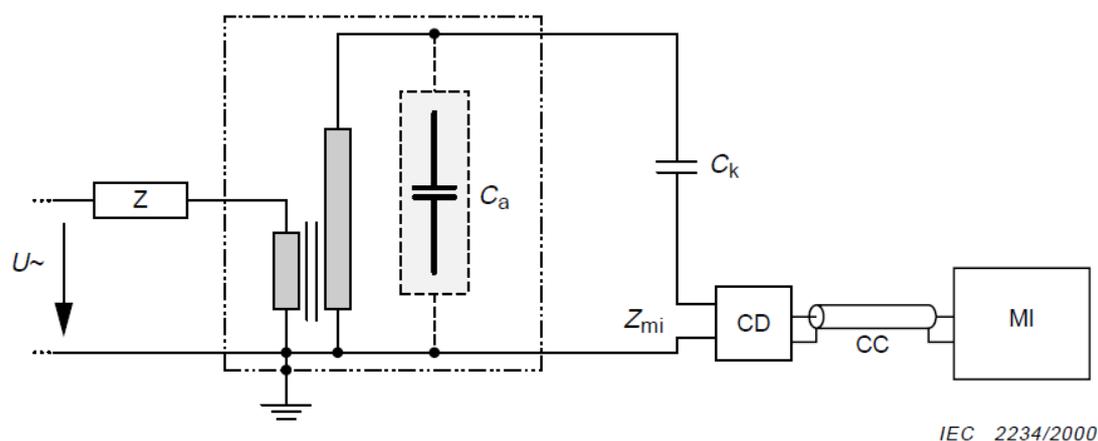


Figura 12 - Arranjo para Medição de Descargas Parciais

onde,

- $U$  é a fonte de tensão, no caso, o regulador de tensão da bancada de controle do Kit de Alta Tensão;
- $C_a$  é o objeto de teste, no caso, a célula de testes;
- $C_k$  é o capacitor de acoplamento;
- $Z$  é um filtro para atenuar a presença de harmônicos provenientes da rede;
- $Z_{mi}$  é a impedância de entrada do sistema de medição;
- $CC$  é um cabo coaxial;
- $MI$  é o instrumento de medição, no caso, o LDIC®.

Na figura a seguir é possível conferir a instalação desses componentes com as devidas identificações nos equipamentos mais relevantes.

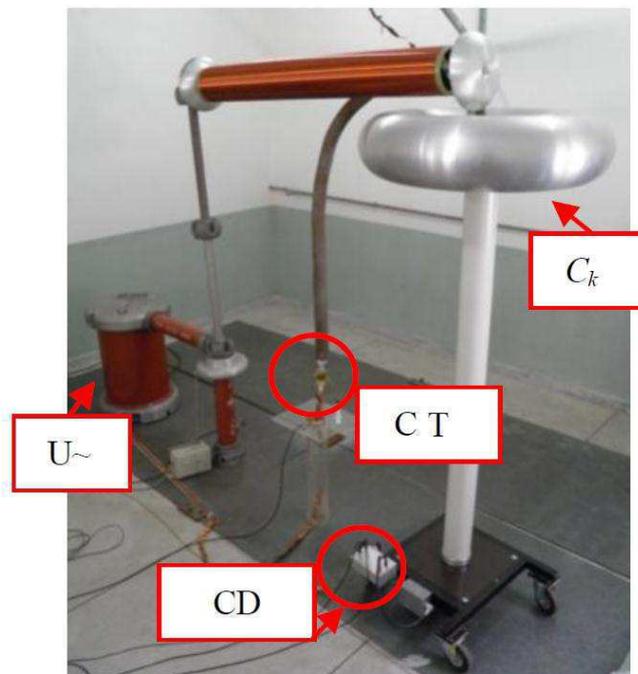


Figura 13 - Montagem do circuito de medição em laboratório.  $CT$  é a célula de teste, representada por  $C_k$  no esquemático da figura anterior e  $CD$  é o  $Z_{mi}$  [10]

Os ensaios foram realizados nos dias 11, 12, 13 e 14 de junho de 2012 e 06 de julho do mesmo ano. Inicialmente realizou-se o procedimento de calibragem do detector de descargas parciais. O LDIC® possui um calibrador próprio que simula sinais de descargas parciais de 5, 20, 100 e 500 pC. Após a calibragem, a amostra era introduzida na célula de teste que era então fechada, rosqueando a parte superior da referida célula. Posteriormente utilizava-se a seringa para sugar o óleo de transformador contido em um recipiente. Esse óleo era então injetado na célula de teste, após fixação apropriada da amostra, tomando-se o devido cuidado para que não ficasse nenhuma espécie de bolha no óleo, para evitar o surgimento de descargas parciais no próprio meio dielétrico e comprometer a qualidade das medições. A tensão aplicada nas amostras foi de 20 kV. Após a elevação da tensão, o sinal de descargas parciais era imediatamente gravado no notebook por intermédio do software do fabricante do detector de DP, obtendo dados referentes a cerca de 1200 ciclos de tensão, o equivalente a 20 segundos de gravação. Após a aquisição dos dados, aguardava-se um período de 5 minutos, e novamente eram realizadas as medições e os dados eram salvos no computador. Cada amostra, da nº 1 à nº10, foi ensaiada cinco vezes, o que nos fornece uma base de dados de 100 arquivos de medição, já que cada uma teve suas medições de DP gravadas duas vezes. Cada arquivo possuía entre 7 e 8 MBytes de dados, salvos no formato *txt*, com as seguintes

informações: número do ciclo, fase da ocorrência da descarga, intensidade da descarga e tensão aplicada no momento da detecção. Essa tensão não estava calibrada durante os ensaios e seu valor deve ser desprezado, porém isso não interfere nos resultados das outras medições.

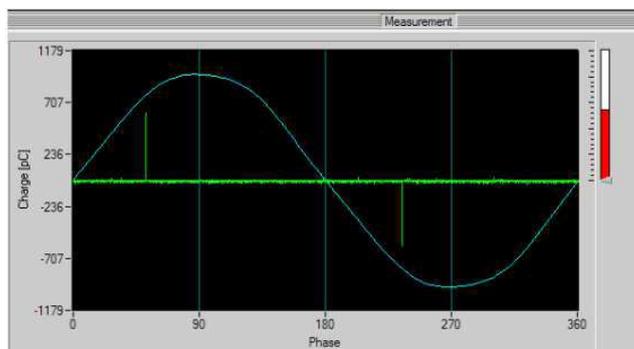


Figura 14 - Imagem obtida do programa LDS-6 durante a medição de DP [10]

### 3.2.2 - Tratamento dos Dados

Inicialmente é necessário filtrar os dados de entrada que possuem muita informação irrelevante para a rede neural, a ser considerado ruído, como pode ser observado ao plotar o nível de descargas parciais em relação à fase da tensão. A imagem mostra dados referentes ao primeiro ciclo da primeira amostra no primeiro ensaio.

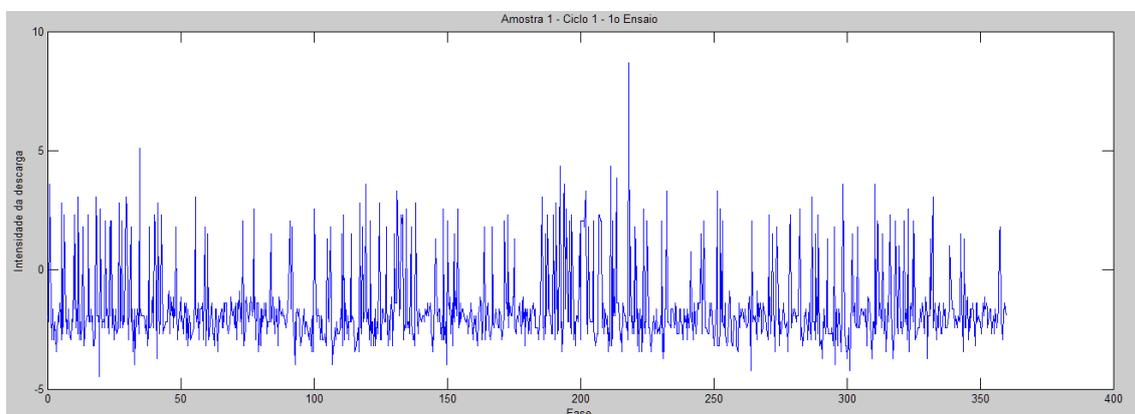


Figura 15 - Resultado da medição antes da filtragem

Para retirar o ruído presente na leitura, simplesmente aplicou-se um limiar que zera todas as leituras que tenham intensidade abaixo de 4 pC. Após esse processo, o gráfico resultante para o mesmo vetor de dados apresenta-se conforme figura abaixo.

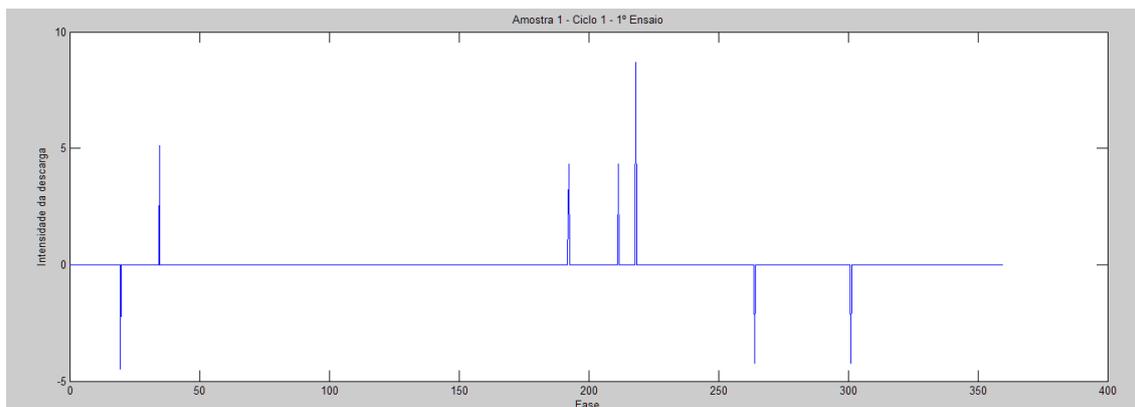


Figura 16 - Dados após filtragem

Esse processo de filtragem é fundamental para não 'confundir' a rede e atrapalhar a classificação dos padrões. Nota-se que a filtragem foi bem sucedida já que a maioria dos pulsos concentram-se nas vizinhanças da fase 0 e 180, local onde ocorrem as descargas parciais em cavidades, pois representa o local com maior  $dv/dt$  da tensão aplicada.

### 3.2.3 - Extração de Atributos

A extração de informações relevantes para a classificação da rede neural é um dos passos mais importantes, senão o mais importante, de todo o processo de identificação dos padrões contidos nos dados coletados e a consequente separação em classes definidas.

Inicialmente utilizou-se de uma abordagem estatística para tratamento das informações que acabou por se demonstrar não muito classificável pela RNA, talvez pela natureza não muito relevante dos dados ou mesmo da incompatibilidade da RNA com o tipo de informação fornecida.

A abordagem final utilizou-se de critérios mais relacionados com a intensidade de pulsos, e, principalmente, com a fase em que eles ocorrem. A fase de surgimento da DP é um dos melhores critérios para ser utilizado como atributo na extração de dados do vetor de informações.

Dessa forma, foram selecionados e extraídos do conjunto de dados 12 parâmetros que foram utilizados na classificação dos dados provenientes da RNA, a saber:

- Quantidade de descargas no semi-ciclo positivo;
- Quantidade de descargas no semi-ciclo negativo;
- Fase da ocorrência da primeira descarga no semi-ciclo positivo;
- Fase da ocorrência da primeira descarga no semi-ciclo negativo;
- Fase da ocorrência da última descarga no semi-ciclo positivo;
- Fase da ocorrência da última descarga no semi-ciclo negativo;
- Somatório das intensidades das descargas, em pC, no semi-ciclo positivo;
- Somatório das intensidades das descargas, em pC, no semi-ciclo negativo;
- Valor em pC da maior descarga do semi-ciclo positivo;
- Valor em pC da menor descarga do semi-ciclo positivo;
- Valor em pC da maior descarga do semi-ciclo negativo;
- Valor em pC da menor descarga do semi-ciclo negativo.

As informações foram coletadas para dados referentes aos 100 primeiros ciclos e armazenados em um vetor 12x100. Para cada conjunto de dados (10 por amostra) foi feito esse procedimento e essa extração de atributos. Dessa forma, ao concatenar essas matrizes, para cada uma das amostras temos um vetor de dados 12x1000 ([12x100 12x100 12x100 ... 12x100]).

Após fazer esse tratamento de dados para todos os defeitos, obteve-se 10 matrizes 12x1000, onde cada uma delas representa uma amostra de pastilhas de fenolite, que foram ensaiadas cinco vezes e colhidos dados duas vezes por ensaio.

Para observar a capacidade de classificação da RNA com os dados fornecidos, a RNA foi executada primeiramente com as amostras 1 e 2, depois 1, 2 e 3, depois 1, 2, 3 e 4, e assim por diante, até a apresentação completa dos dados. Em cada um desses casos, variou-se a quantidade de neurônios buscando-se obter a menor porcentagem de erro possível. A divisão dos dados apresentados à RNA foi de 75% para treinamento, 15% para validação e 15% para o teste.

## 4 – Resultados

Para resolução do problema foi utilizado um notebook com processador Intel® Core™ i7-2630QM com CPU em *clock* de 2.00 GHz, com 8GB de memória ram. É interessante notar que o processo de treinamento da RNA demandou um esforço computacional de cerca de 50% do processador, visto que sem rodar o algoritmo o computador funcionava com 4% de seu poder de processamento e durante a solução desse problema esse esforço salta para 54%. Nota-se que é necessário um bom equipamento para que a RNA seja treinada em tempo hábil.

Para iniciar o toolbox do Matlab® de redes neurais para reconhecimento de padrões basta digitar o comando *nprtool* na área de trabalho do software. No *wizard* que se abre, deve-se entrar com dois vetores. Um de dados de entrada é uma matriz do tamanho da quantidade de ciclos das amostras envolvidas na análise pela quantidade de parâmetros de entrada. O segundo vetor é uma matriz de alvos. Para cada ciclo, deve-se por o valor '1' para a amostra alvo e '0' para as demais. Por exemplo, se eu tenho uma matriz de entrada 12x2000, estou analisando duas pastilhas de fenolite. Então minha matriz alvo será 2x1000, onde na linha 1 da posição 1 até a 1000 deverá conter o valor 1 e na linha 2 da posição 1001 até a 2000 deverá conter também o valor 1. Os demais valores devem ser zero. Assim foi possível utilizar a RNA para classificação dos padrões.

Após entrada das matrizes de parâmetros e alvo, deve-se escolher a quantidade de neurônios existentes nas camadas da RNA. Como cada caso de defeito, seja a análise do 1º, 2º ou do 1º ao 10º, pode apresentar a solução ótima para uma determinada quantidade de neurônios diferentes, a busca por essa solução foi feita por tentativa e erro até que se obtivesse um melhor resultado após uma série de tentativas com diferentes quantidades de neurônios.

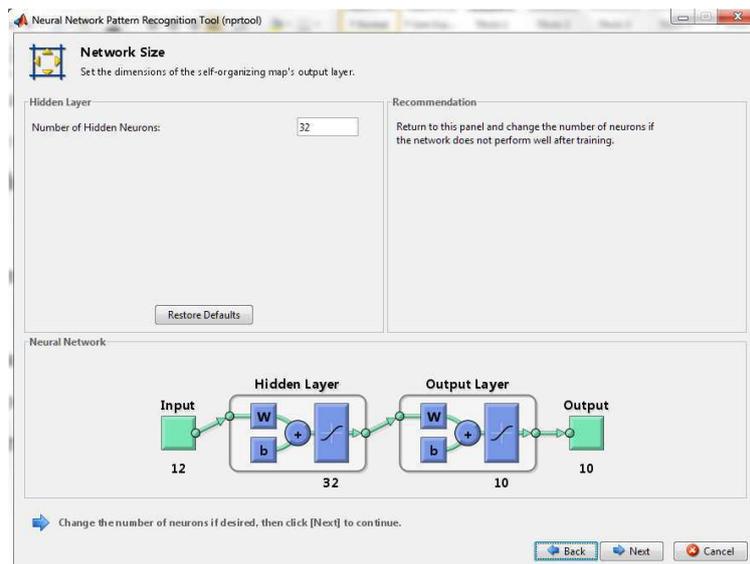


Figura 17 - Wizard do Matlab de RNAs: Seleção da quantidade de neurônios. Nesse caso, com todas as pastilhas sob análise e 32 neurônios na camada oculta

É de se esperar que com o aumento da quantidade de amostras a serem analisadas ao mesmo tempo, a rede erre numa proporção cada vez maior. De fato, foi isso que ocorreu. A porcentagem de erro da análise apenas com o primeiro e segundo defeito foi significativamente inferior à análise com todos os defeitos. Isso se deve ao aumento da complexidade do problema. Entretanto os resultados foram relativamente satisfatórios, dado que na primeira tentativa, com parâmetros meramente estatísticos, a porcentagem de erro beirava os 90%.

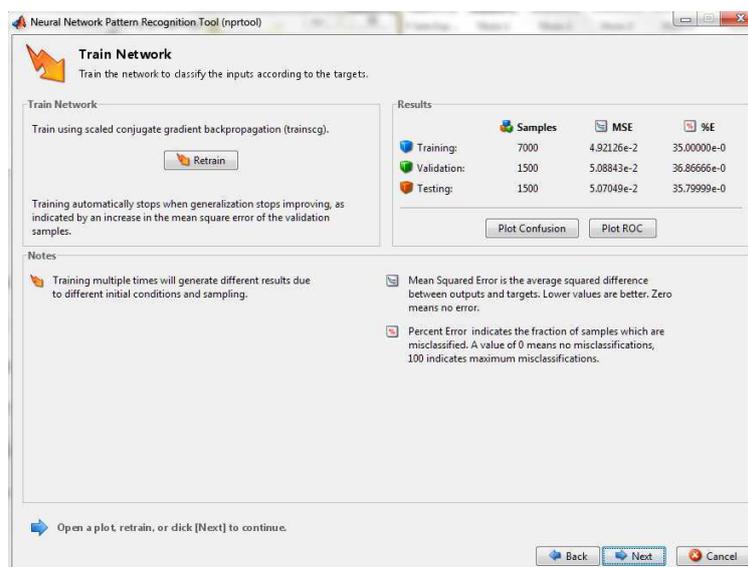


Figura 18 - Tela pós-solução. %E indica a porcentagem de erro nas etapas de solução

Além disso é possível avaliar a convergência da solução observando-se o erro médio quadrático. Na figura abaixo, é possível verificar o erro médio para a rede que

analisa todas as pastilhas de fenolite. O número de épocas é a quantidade de iterações necessárias à convergência do problema.

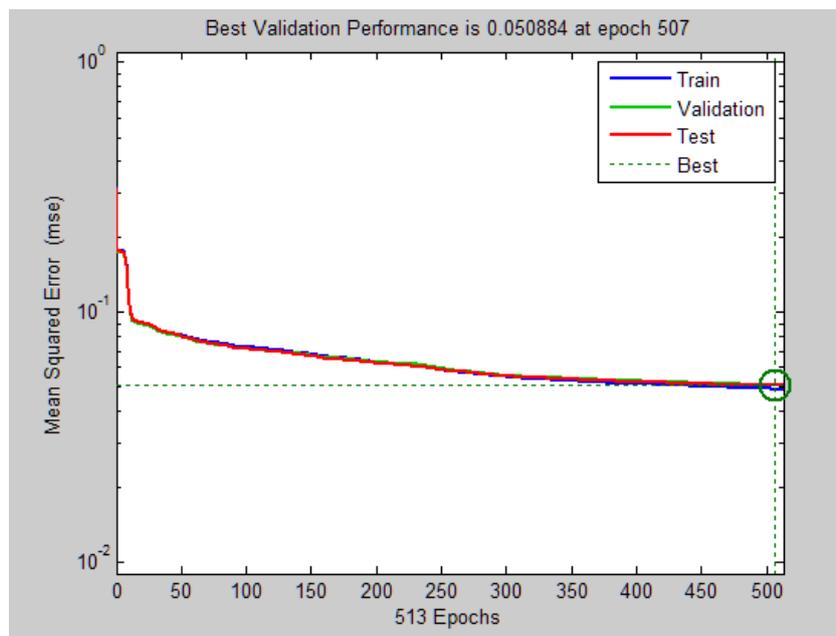


Figura 19 - Erro médio quadrático

Finalmente, na tabela abaixo, é possível conferir o resultado das análises para todas as quantidades de pastilhas analisadas.

Tabela 2 – Resultado da RNA

Pastilhas de Fenolite	Número de neurônios na camada oculta	% de Acerto da RNA	% de erro da RNA
1 <sup>a</sup> e 2 <sup>a</sup>	18	90,40	9,60
1 <sup>a</sup> , 2 <sup>a</sup> e 3 <sup>a</sup>	16	80,45	19,55
1 <sup>a</sup> à 4 <sup>a</sup>	21	73,17	26,83
1 <sup>a</sup> à 5 <sup>a</sup>	23	72,94	27,06
1 <sup>a</sup> à 6 <sup>a</sup>	23	70,66	29,33
1 <sup>a</sup> à 7 <sup>a</sup>	30	68,96	31,04
1 <sup>a</sup> à 8 <sup>a</sup>	27	62,75	37,25
1 <sup>a</sup> à 9 <sup>a</sup>	31	66,08	33,92
1 <sup>a</sup> à 10 <sup>a</sup>	32	64,21	35,79

Os dados da Tabela 2 também podem ser conferidos na forma de gráfico, como na figura abaixo.

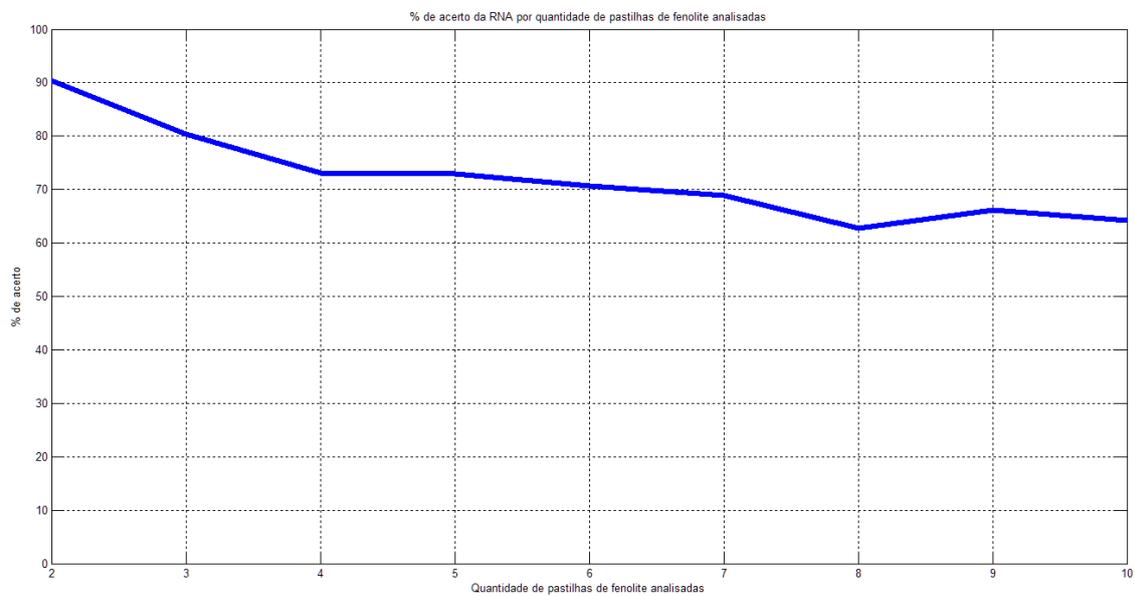


Figura 20 - Porcentagem de acerto da RNA por quantidade de pastilhas de fenolite analisadas

## 5 – Conclusões

Após análise dos dados obtidos através da classificação realizada pela Rede Neural Artificial, foi possível constatar que o algoritmo é capaz de separar amostras de diferentes configurações de defeitos propositalmente inseridos fazendo uso da informação de pulsos de descargas parciais coletados através de instrumentos de medição comerciais.

Constata-se que esses dados possuem informações acerca da disposição espacial e quantitativa de defeitos em forma de cavidades que existem dentro de isolantes e por isso seu estudo é de vital importância, visto que se abre uma infinidade de possibilidades com relação à utilização dessa informação para avaliar a presença e a disposição de cavidades em isoladores poliméricos, verificando em que parte do equipamento esses defeitos se encontram com maior intensidade e, portanto, no futuro, intervir no processo de fabricação do isolador visando a redução da concentração desses defeitos.

A classificação de diferentes tipos de disposição de defeitos através da análise de sinais de descargas parciais apresentou resultados satisfatórios dentro das limitações do algoritmo. Verificou-se uma taxa de acerto superior a 90% para um número pequeno de considerações de defeitos, mas uma taxa reduzida a 64% de acertos por parte da RNA quando se leva em consideração o maior leque de padrões de defeitos. Tal fato se dá pela escolha dos parâmetros de entrada da RNA e também pela própria estrutura da rede. Pode-se afirmar que a limitação de construir uma RNA de apenas duas camadas, imposta pelo MATLAB®, estreitou as possibilidades de análise do problema, visto que a quantidade de neurônios de cada um desses resultados influenciou na porcentagem de acerto, nada mais natural supor que a quantidade de camadas de neurônios também teria um efeito decisivo na taxa de acerto da RNA.

Futuros trabalhos relacionados a esse tema seriam o refinamento da RNA em busca de melhores taxas de acertos, utilizando-se de redes com outras características, como a *Resilient Propagation*, uma variação inteligente do método *back propagation*, utilizado no toolbox do Matlab®, além da maior liberdade para escolha da quantidade de camadas. Outra abordagem a ser levantada é um maior número de ensaios de alta tensão para se obter uma base de dados mais generalizada e confiável visando obter uma melhor distinção das características de cada padrão de defeito a ser analisado.

## 6 – Referências Bibliográficas

- [1] D. A. Nattrass, “Partial Discharge Measurement and Interpretation,” *IEEE Electrical Insulation Magazine*, Junho 1988.
- [2] T. G. S. Encyclopedia, “Electrical Insulation,” 1970. [Online]. Available: <http://encyclopedia2.thefreedictionary.com/Electrical+Insulation>. [Acesso em 26 Outubro 2012].
- [3] J. F. Hall, “HISTORY AND BIBLIOGRAPHY OF POLYMERIC INSULATORS FOR OUTDOOR APPLICATIONS,” *IEEE Transactions on Power Delivery*, pp. 376-378, Janeiro 1993.
- [4] S. A. Boggs, “Partial Discharge: Overview and Signal Generation,” *IEEE Electrical Insulation Magazine*, p. 33, Julho/Agosto 1990.
- [5] R. Bartnikas, “Partial Discharges: Their Mechanism, Detection and Measurement,” *IEEE Transactions on Dielectrics and Electrical Insulation*, p. 763, Outubro 2002.
- [6] E. Kuffel, W. Zaengl e J. Kuffel, *High Voltage Engineering - Fundamentals*, Woburn: Butterworth-Heinemann, 2000.
- [7] B. Krose e P. v. d. Smagt, *An Introduction To Neural Networks*, 8ª ed., Amsterdam: The University of Amsterdam, 1996.
- [8] T. V. Ferreira, “Estimação Inteligente Da Poluição De Isolamentos Elétricos Baseada Nos Vecse Do Ruído Ultrassônico,” Tese de Doutorado, Campina Grande, 2011.
- [9] MATLAB®, *Neural Network Toolbox Design Book*.
- [10] E. C. T. Macêdo, J. M. Villanueva, E. G. Costa, R. C. Freire, D. B. Araújo e I. A. Glover, “Identification of Insulation Defect Configuration using a Neural Network to Classify Partial Discharge Signals,” *International Power Modulator and High Voltage Conference*, Junho 2012.
- [11] Lemke®, “Manual do Usuário - LDIC”.

## Anexo

### Código em linguagem Matlab® para extração de atributos do sinal de descargas parciais

```

%UFCG/CEEI/DEE
%Igor de Sousa Medeiros Torres
%Código para cálculo de parâmetros
%Nome da variável proveniente dos arquivos: data

%COLETANDO DADOS DOS PRIMEIROS 100 CICLOS:

clc
clear all

load C:\Users\Igor\Documents\EE\TCC\Dados\Defeito1\Montagem1.mat

%Aplicação do Threshold
for i=1:length(data)
    if(abs(data(i,3))<4)
        data(i,3)=0;
    end
end

ciclo=1;
cont=1;
flag1=1;
flag2=1;
pulsos100 = zeros(1,100);
%Criacao de variaveis
SemiC_P = zeros(1,100); %numero de dados de semiciclos negativos e
positivos
SemiC_N = zeros(1,100);
Fases_P = zeros(1,100);
Fases_N = zeros(1,100);
Fases_Pfim = zeros(1,100);
Fases_Nfim = zeros(1,100);
Soma_P = zeros(1,100);
Soma_N = zeros(1,100);
Maximos_P = zeros(1,100); % maior valor de pico para semiciclo positivo
Maximos_N = zeros(1,100); % maior valor de pico para semiciclo negativo
Minimos_N = 100.*ones(1,100); % menor de pico para semiciclo negativo
Minimos_P = 100.*ones(1,100); % menor de pico para semiciclo positivo
% Desv_P = zeros(1,100); %desvios padrao semiciclo positivo
% Desv_N = zeros(1,100); %desvios padrao semiciclo negativo
%Numero de pulsos por ciclo
% Assim_P = zeros(1,100);
% Assim_N = zeros(1,100);
%
```

```

% Curtose_P = zeros(1,100);
% Curtose_N = zeros(1,100);

while(ciclo<101)

    while(data(cont,1)==ciclo)

        if((abs(data(cont,3))>0)&&(data(cont,2)<180))
            SemiC_P(1,ciclo)= SemiC_P(1,ciclo)+1;    %Contagem da quantidade
de pulsos em cada semiciclo positivo
            if(abs(data(cont,3))>abs(Maximos_P(1,ciclo)))
                Maximos_P(1,ciclo) = data(cont,3); %Busca por maior valor de
pico positivo do semiciclo
            end
            if((abs(data(cont,3))<abs(Minimos_P(1,ciclo)))&&(data(cont,3)~=0))
                Minimos_P(1,ciclo) = data(cont,3); %Busca por menor valor de
pico positivo do semiciclo
            end

            if(flag1)
                Fases_P(ciclo) = data(cont,2);    %Aquisição da fase do
primeiro pulso no semiciclo positivo
                flag1=0;
            end
            Fases_Pfim(1,ciclo) = data(cont,2); %Aquisicao da fase do
último pulso no semiciclo
            Soma_P(1,ciclo) = Soma_P(1,ciclo)+abs(data(cont,3));
        end
        if((abs(data(cont,3))>0)&&(data(cont,2)>=180))
            SemiC_N(1,ciclo)= SemiC_N(1,ciclo)+1;    %Contagem da quantidade
de pulsos em cada semiciclo negativo

            if(abs(data(cont,3))>abs(Maximos_N(1,ciclo)))
                Maximos_N(1,ciclo) = data(cont,3); %Busca por maior valor de
pico positivo do semiciclo
            end

            if((abs(data(cont,3))<abs(Minimos_N(1,ciclo)))&&(data(cont,3)~=0))
                Minimos_N(1,ciclo) = data(cont,3); %Busca por menor valor de
pico positivo do semiciclo
            end

            if(flag2)
                Fases_N(ciclo) = data(cont,2);    %Aquisição da fase do
primeiro pulso no semiciclo positivo
                flag2=0;
            end
            Fases_Nfim(1,ciclo) = data(cont,2); %Aquisicao da fase do
último pulso no semiciclo
            Soma_N(1,ciclo) = Soma_N(1,ciclo)+abs(data(cont,3));
        end

        cont=cont+1;
    end
    flag1=1;
end

```

```
flag2=1;

if(Minimos_P(1,ciclo)==100) %Para ciclos em que o mínimo foi igual
a 0.
    Minimos_P(1,ciclo)=0;
end

if(Minimos_N(1,ciclo)==100)
    Minimos_N(1,ciclo)=0;
end

ciclo=ciclo+1;

end

SAIDA =
[SemiC_P;SemiC_N;Fases_P;Fases_N;Fases_Pfim;Fases_Nfim;Soma_P;Soma_N;M
aximos_P;Maximos_N;Minimos_P;Minimos_N];

save Def1_1 SAIDA %Variável de saída após a extração de atributos
```