

**SENDI 2004**

**XVI SEMINÁRIO NACIONAL DE DISTRIBUIÇÃO DE ENERGIA ELÉTRICA**

**Metodologia Utilizando Redes Neurais para Identificação de Transformadores Queimados de uma Concessionária de Distribuição de Energia Elétrica**

**Deus,R. - Celpa – Centrais Elétricas do Pará S.A. / Elucid Solutions S.A. / UFPA – Universidade Federal do Pará , rosilena.deus@elucid.com.br**

**Tavares,W. - Celpa – Centrais Elétricas do Pará S.A. / Elucid Solutions S.A. / UFPA – Universidade Federal do Pará , walbert.tavares@elucid.com.br**

**Palavras chaves**

**Distribuição de Energia - Modelagem Kohonen - Rede Neural - Transformadores**

## RESUMO

Este trabalho descreve uma metodologia para identificar a possível queima de um transformador de distribuição com a utilização de uma rede neural com modelagem Kohonen. Identificou-se, junto à concessionária, quais as características que melhor definiam a queima de um transformador, sendo que algumas delas foram codificadas para que pudessem ser apresentadas como dado de entrada à rede. Depois de definidos os dados de entrada, partiu-se para a modelagem da rede neural (quantidade de neurônios da camada competitiva, critério de parada, etc). Após modelagem, iniciou-se a fase de treinamento da rede. Nesta fase, parâmetros como a velocidade de aprendizado e a quantidade de interações foram definidos. A rede foi considerada treinada após todo o conjunto de treinamento ter sido apresentado à rede, e os critérios de treinamento terem sido satisfeitos. Uma aplicação prática, utilizando a base de dados das Centrais Elétricas do Pará S.A. foi executada, atingindo-se uma eficiência de até 95% na previsão de queima de transformadores. Este valor pode ser melhorado através de uma análise mais minuciosa sobre os dados de entrada da rede, ou seja, de acordo com os dados que as empresas possam disponibilizar do seu histórico e que possam ser utilizados para novo treinamento da rede.

## **1 . INTRODUÇÃO**

Uma das buscas constantes das concessionárias de energia elétrica é tentar diminuir a quantidade de transformadores de distribuição que sofrem avaria (queima), para poder auxiliar a Centrais Elétricas do Pará a identificar quais os transformadores que possivelmente possam vir a queimar e consequentemente evitar a queima do mesmo foi desenvolvida uma metodologia que utiliza métodos de inteligência artificial (rede neural) para indicar quais são estes transformadores.

Para melhor entendimento da metodologia proposta o trabalho foi dividido em 05 seções, sendo que a primeira seção apresenta uma fundamentação teórica sobre redes neurais e modelagem Kohonen; na seção três descreve-se a metodologia utilizando rede neural com modelagem Kohonen desenvolvida para identificação dos transformadores de distribuição queimados das Centrais Elétricas do Pará, quais os estudos iniciais necessários, definição dos parâmetros da rede estudada, etc ; na seção quatro mostra-se os resultados alcançados e a eficiência da rede e , por fim, na seção cinco as conclusões obtidas.

Para utilizar a metodologia proposta foi modelado e desenvolvido um software que também será citado ao longo do trabalho.

O objetivo principal do estudo que era utilizar com uma boa eficiência as redes neurais com modelagem Kohonen para indicar a possível queima de transformadores de distribuição queimados de uma concessionária foi atingido, com isto poderemos partir para estudos de aprimoramento da metodologia e do software utilizados, assim como para a expansão da utilização da metodologia em outras áreas de uma empresa de energia elétrica.

## **2. FUNDAMENTAÇÃO TEÓRICA**

### ***2.1. Redes Neurais***

As Redes Neurais Artificiais (RNAs) são modelos matemáticos que se assemelham às estruturas biológica, os neurônios, e que tem a capacidade computacional adquirida por meio de aprendizado e generalização (Haykin, 2002).

O aprendizado em RNAs está normalmente associado a capacidade das mesmas adaptarem seus parâmetros como consequência da sua interação com o meio externo. O processo de aprendizagem é interativo e por meio dele a RNA deve melhorar seu desempenho gradativamente à medida que interage com o meio externo.

O processamento da informação em RNAs é feito por meio de estruturas neurais artificiais, em que o armazenamento e o processamento da informação são realizados de maneira paralela e distribuída por elementos processadores. Cada elemento processador corresponde a um neurônio artificial.

### ***2.2. Modelo de Kohonen***

O pesquisador finlandês Teuvo Kohonen possui uma longa história de pesquisas no campo de modelos para descoberta de interrelacionamentos intrínsecos em distribuições de padrões, que se iniciou com pesquisas na área da Análise de Componentes Principais e quantização de atributos em conjuntos de vetores (pesquisa descrita em seu primeiro livro na área) e foi evoluindo no sentido de tentar descrever modelos cada vez mais plausíveis do ponto de vista biológico. O objetivo de suas

pesquisas, na década de 1980, passou a ser o de descobrir um modelo de auto-organização de informações em um processo de aprendizado indutivo capaz de ser usado como modelo para o aprendizado e organização de informações no neocórtex cerebral de um animal superior [Koho88].

O modelo deveria ser capaz de explicar como estímulos similares são aprendidos e agrupados em áreas próximas no cérebro de um animal e levam a uma posterior categorização desses estímulos, e à formação subsequente de um modelo de mundo, criando uma explicação implícita do que foi percebido, através dos agrupamentos de estímulos relacionados em categorias na memória e realizando o processo inteligente da abstração.

Este modelo é uma rede neural tipo feed forward não supervisionada que usa simples neurônios adaptativos para receber sinais de um evento espacial, consistindo de medidas ou dados, como frequência ou situação. Considerando uma rede de duas dimensões, o paradigma de Kohonen não impõe, em absoluto, nenhuma forma topológica, podendo ser hexagonal, retangular, triangular, etc.

Conforme Kohonen (1988), o esquema básico deste modelo faz com que os neurônios da camada de saída disputem entre si a representação da informação apresentada aos neurônios de entrada. Havendo um neurônio vencedor, este é reajustado para responder ainda melhor ao estímulo recebido. Dentro deste modelo não supervisionado, não somente o vencedor, mas também os seus vizinhos (dentro de um senso físico) são ajustados.

Este “comportamento” tem por objetivo fazer com que a rede simule uma atividade cerebral. Este paradigma é baseado na teoria de que as células nervosas corticais estão arranjadas anatomicamente em relação aos estímulos que recebem dos sensores às quais estão ligadas.

### **2.3 . O Mecanismo da Rede de Kohonen**

Sinteticamente, o mecanismo deste modelo funciona da seguinte forma, os pesos sinápticos iniciam contendo valores aleatoriamente baixos, e um sinal de entrada X (com valores que representam uma informação qualquer) é provido para a rede sem que se especifique a saída desejada (característica da rede não supervisionada). O sinal de entrada X é descrito como:  $X = [X_1, X_2, X_3, \dots, X_n]^{1n}$

Conforme o sinal de entrada, um neurônio de saída y deverá responder melhor para a entrada respectiva e, então, será o vencedor. Isto faz com que este neurônio seja disparado sempre que essa entrada específica for apresentada à rede neural. O neurônio vencedor y, e seus vizinhos (Vy), terão seus pesos sinápticos ajustados para responder melhor do que antes à entrada apresentada X. A rede é considerada treinada depois de todo o conjunto de treinamento ter sido apresentado à rede, e os critérios de treinamento terem sido satisfeitos. Segue depois a fase de treinamento, só que não serão mais alterados os pesos dos neurônios. Para que o teste seja mais apurado, a rede poderá receber, como entrada, além dos fatos que foram apresentados, outros que não fizeram parte do conjunto de treinamento.

Reconhecendo as entradas do teste de forma adequada a rede é considerada treinada com sucesso.

## **3 . METODOLOGIA UTILIZANDO REDE NEURAL COM MODELAGEM KOHONEN PARA O DIAGNÓSTICO DOS TRANSFORMADORES DE DISTRIBUIÇÃO QUEIMADOS DAS CENTRAIS ELÉTRICAS DO PARÁ**

### **3.1. Estudo da escolha dos dados que deverão caracterizar os transformadores queimados e não queimados**

Para este estudo foi necessário primeiramente pesquisar junto a Centrais Elétricas do Pará quais eram os dados que a empresa tinha disponível em seu banco de dados técnicos e que poderiam caracterizar a queima de um transformador.

As características escolhidas foram as citadas abaixo, sendo que todos os transformadores estudados são de propriedade e manutenção da própria empresa.

Tabela 1: Características/Atributos retiradas do banco de dados da companhia para treinamento da rede.

<b>Características:</b>	<b>Descrição</b>
01	Marca
02	Potência
03	Quantidade de Unidades Consumidoras - UCs faturadas
04	Quantidade de UC's na topologia
05	Consumo medido (kwh)
06	Quantidade de ocorrências no ano
07	Causa da última interrupção
08	Quantidade de interrupções com a causa Falha de Equipamentos no ano
09	Quantidade de interrupções com a causa Terceiros/Vandalismo no ano

As características 1 e 2 foram escolhidas pois de acordo com levantamentos efetuados junto aos engenheiros da empresa havia informações que determinadas marcas de transformadores queimavam mais do que outras e que isto também dependia da potência, por exemplo, há mais registro de transformadores queimados de 45 e 75 kVA.

As características 04 e 05 determinam se o transformador está com perdas comercial, pois pela diferença entre a quantidade de uc's que estão ligadas e a quantidade de uc's faturadas podemos verificar o montante de clientes que não estão pagando suas faturas. Estas não seriam características basicamente técnicas, mas que achamos interessante acrescentar para ver se poderíamos relacionar a queima de um transformador com as perdas comerciais. Para os transformadores queimados foram utilizados os dados do mês anterior a queima e para os transformadores bons foram utilizados os dados do mês de julho de 2003.

A característica 05 determina o consumo do transformador, como não tínhamos no banco de dados da Celpa o histórico do carregamento dos transformadores, resolvemos utilizar o consumo medido nos transformadores, sendo que para os queimados foram utilizados os consumos do último mês anterior a queima e para os bons o consumo medido no mês de julho de 2003. Em uma comparação da coluna da potência do transformador com o consumo medido pode existir uma indicação que o transformador pode ter queimado porque estava sobrecarregado.

As características 06, 07, 08 e 09 determinam as interrupções ocorridas nos transformadores, achamos estas características importantes visto que durante a nossa experiência na operação da distribuição, notamos que os transformadores que queimavam geralmente já tinham tido outras interrupções anteriormente e geralmente as causas destas interrupções eram semelhantes, no levantamento dos dados confirmamos este fato e notamos que verificamos que as causas das interrupções anteriores a queima eram na maioria de falha de equipamentos ou de terceiro/vandalismo, sendo que ligações clandestinas, que é uma causa muito freqüente, se enquadra dentro da causa terceiro/vandalismo. Para os transformadores queimados o número de ocorrências no ano e os números de interrupções por falha de equipamento e terceiro/vandalismo foram levantados durante os 12 meses anteriores a queima e para os transformadores bons durante os meses de agosto de 2002 e julho de 2003. Algumas características tiveram que ser codificadas para permitir a utilização da mesma no banco de dados de entrada. As características codificadas estão apresentadas na tabela 2, com a respectiva descrição seguida do código.

Tabela 2: Características dos transformadores seguidas dos respectivos códigos.

Marca	Cd	Potência	Cd	Causa	Cd
WTW	01	10 KVA	01	Albaroamento por veículo	01
TRAFO	02	15 KVA	02	Árvore	02
ROMAGN OLE	03	30 KVA	03	Ave/Animal	03
IMAN	04	45 KVA	04	Descarga atmosférica	04
CEMEC	05	75 KVA	05	Falha humana	05
ITAIPU	06	112,5 KVA	06	Fogo / Queimadas	06
TOSHIBA	07	150 KVA	07	Pipa	07
UNIÃO	08	225 KVA	08	Sobrecarga	08
TUSA	09			Outros	09
FALEG	10			Falha em equipamentos	10
SEMIN	11			Terceiros / Vandalismo	11
BIRIGUI	12			Vento	12
ITEL	13				
WEG	14				
MARANG ONI	15				
BELINA	16				
NATIVA	17				
SIEMENS	18				
CROSS	19				
TTL	20				
ROMA	21				

### 3.2. Dados de treinamento e dados de testes

Das 113 amostras utilizadas do banco de dados, 93 foram utilizadas para treinamento e 20 para testes.

### 3.3. Padrão de entrada

O sinal de entrada será uma matriz da seguinte forma:  $X = [X_1, X_2, X_3, X_4, X_5, X_6, X_7, X_8, X_9]$ , sendo que os padrões  $X_1$  até  $X_9$  correspondem aos atributos de 3 a 11 do banco de dados.

### 3.4. Classes/Quantidade de neurônios da camada competitiva

Foram utilizadas somente duas classes, sendo que uma determina avaria e outra não avaria, logo a quantidade de neurônios da camada competitiva é igual a dois. Observe que a figura 1 possui dois neurônios representados pelas figuras ovais e nove entradas representado as características que serão apresentadas a rede.

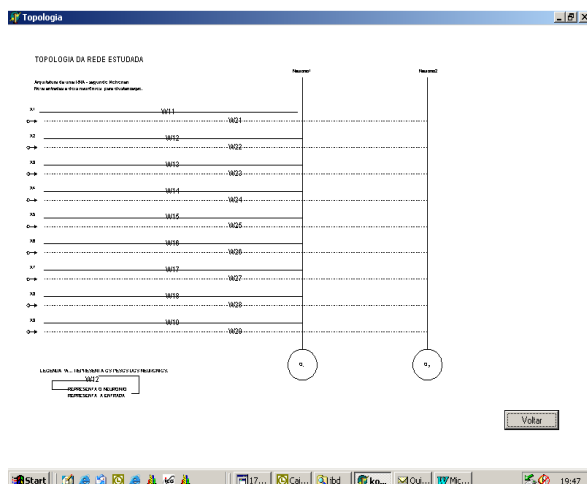


Figura 1: Tela da aplicação que mostra a topologia da rede apresentada.

### 3.5. Critério de parada

O critério de parada utilizado foi a quantidade de interações, sendo que uma interação corresponde a apresentação das entradas de todas as amostras de treinamento. Utilizou-se exemplos de parada com 100, 200 e 500 interações.

### 3.6. Algoritmo utilizado para treinar a rede

Passo 0. Inicialização dos pesos  $W_{ji}$  (aleatória)

Inicialização dos parâmetros de vizinhança

## Inicialização dos parâmetros de aprendizagem

Passo 1 . Enquanto a condição de parada for falsa, executar os passos de 2 a 8

Passo 2 . Para cada vetor de entrada X, executar os passos de 3 a 5

Passo 3 . Para cada j, calcular:

$$D(j) = \sum (W_{ji} - X_i)^2 \quad (1)$$

Onde :

D(j) = distância do entre o neurônio j da camada competitiva e cada neurônio i da camada de entrada ;

$W_{ji}$  = peso sináptico entre o neurônio de entrada i e o neurônio de saída j;

$X_i$  = valor do neurônio de entrada i

Passo 4 . Seleção do neurônio vencedor

Calcular o índice J tal que D(J) seja mínimo.

Passo 5 . Atualização dos pesos do neurônio vencedor da vizinhança do neurônio vencedor para todas as unidades j dentro de uma vizinhança de J e para todos os i:

$$W_{ji}(t+1) = W_{ji}(t) + \gamma(X_i - W_{ji}(t)) \quad (2)$$

Onde :

$W_{ji}$  = peso sináptico entre o neurônio de entrada i e o neurônio de saída j;

$X_i$  = valor do neurônio de entrada i;

$\gamma$  é a velocidade de aprendizado

Passo 7 . Redução do raio R da vizinhança topológica

Passo 8 . Teste da condição de parada de treinamento.

### **3.7 . Determinação dos parâmetros de vizinhança e dos parâmetros de aprendizagem**

Com 02 classes e dois neurônios apenas na camada competitiva representando as mesmas, a vizinhança do nó J (Passo 4) terá um R=0 (raio da vizinhança) para todas as interações.

O valor inicial da velocidade de aprendizado  $\gamma$  pode ser determinado pelo próprio usuário, recomenda-se a utilização de valores entre 0,1 e 0,9, e ao decorrer do treinamento em cada interação a mesma pode ser decrescida de acordo com a seguinte equação :  $\gamma(t+1) = \beta \gamma(t)$  (3), onde  $\beta$  corresponde a taxa de decaimento, sendo que esta taxa também pode ser definida pelo próprio usuário.



### 3.8. Treinamentos da rede

Foram realizados 03 treinamentos utilizando-se os seguintes dados:

Primeiro treinamento:

pesos aleatórios  
taxa de decaimento = 0.9  
velocidade de aprendizado = 0.99  
interação/época = 100

Segundo treinamento:

pesos aleatórios  
taxa de decaimento = 0.9  
velocidade de aprendizado = 0.5  
interação/época = 200

Terceiro treinamento:

pesos aleatórios  
taxa de decaimento = 0.8  
velocidade de aprendizado = 0.8  
interação/época = 500

Todos os procedimentos descritos até aqui foram modelados e implementados em software, sendo que o formulário apresentado na figura abaixo representa a aplicação do algoritmo de Kohonen, levando em consideração todos os parâmetros apresentados e traz as seguintes funcionalidades:

- Gerar automaticamente de forma aleatória os vetores de pesos utilizados pela RNA;
- Definir a taxa de decaimento e a velocidade de aprendizagem inicial;
- Definir o número de épocas/interações para que a RNA encerre o treinamento;
- Executar o aprendizado;
- Visualizar as bases de dados;
- Limpar os valores do Formulário;
- Entrar com valores para testar a RNA;
- Executar os Testes.

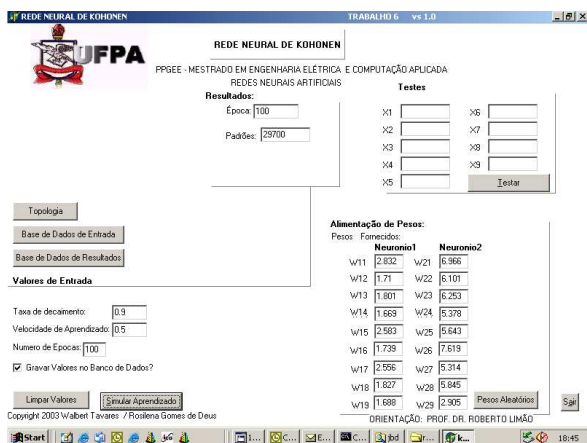


Figura 2: Tela da Aplicação do Algoritmo de Kohonen.

## 4. RESULTADOS OBTIDOS

### 4.1 Resultados dos treinamentos da rede

Primeiro treinamento (100 interações)

Depois do treinamento ter sido realizado utilizando-se os parâmetros descritos anteriormente, observamos que das 93 amostras de treinamento 56 apontaram como vencedor o neurônio 1 e 37 apontaram como vencedor o neurônio 2, como das 56 amostras que apontaram o neurônio 1 como vencedor 47 representavam o estado 1 (transformador queimado) e como das 37 amostras que apontaram o neurônio 2 como vencedor 31 representavam o estado 0 (transformador bom), conclui-se que para este treinamento o estado 0 é representado pelo neurônio 2 e o estado 1 é representado pelo neurônio 1.

Segundo treinamento (200 interações)

Depois do treinamento ter sido realizado utilizando-se os parâmetros descritos anteriormente, observamos que das 93 amostras de treinamento 61 apontaram como vencedor o neurônio 1 e 32 apontaram como vencedor o neurônio 2, como das 61 amostras que apontaram o neurônio 1 como vencedor 49 representavam o estado 1 (transformador queimado) e como das 32 amostras que apontaram o neurônio 2 como vencedor 28 representavam o estado 0 (transformador bom), conclui-se que para este treinamento o estado 0 é representado pelo neurônio 2 e o estado 1 é representado pelo neurônio 1.

Terceiro treinamento (300 interações)

Depois do treinamento ter sido realizado utilizando-se os parâmetros descritos anteriormente, observamos que das 93 amostras de treinamento 55 apontaram como vencedor o neurônio 1 e 38 apontaram como vencedor o neurônio 2, como das 55 amostras que apontaram o neurônio 1 como vencedor 51 representavam o estado 1 (transformador queimado) e como das 38 amostras que

apontaram o neurônio 2 como vencedor 36 representavam o estado 0 (transformador bom), conclui-se que para este treinamento o estado 0 é representado pelo neurônio 2 e o estado 1 é representado pelo neurônio 1.

I0	I1	I2	I3	I4	Vencedor	D1	D2	Va	W1	W2	W3	W4
2	1	1	1	1	6.085	191.307	9.71039584290387E-47	2.832	1.71	1.801	1.68	1.68
7	4	1	1	1	7.19	197.915	9.71039584290387E-47	2.832	1.71	1.801	1.68	1.68
7	9	2	1	1	7.302	203.543	9.71039584290387E-47	2.832	1.71	1.801	1.68	1.68
2	1	1	2	1	463.406	118.756	9.71039584290387E-47	2.832	1.71	1.801	1.68	1.68
8	9	1	2	1	142.216	44.777	9.71039584290387E-47	2.832	1.71	1.801	1.68	1.68
7	7	1	2	1	256.176	40.375	9.71039584290387E-47	2.832	1.71	1.801	1.68	1.68
3	1	1	1	1	4.526	186.983	9.71039584290387E-47	2.832	1.71	1.801	1.68	1.68
9	10	1	2	1	246.802	105.501	9.71039584290387E-47	2.832	1.71	1.801	1.68	1.68
7	6	1	1	1	5.198	171.119	9.71039584290387E-47	2.832	1.71	1.801	1.68	1.68
8	9	2	2	1	90.848	67.973	9.71039584290387E-47	2.832	1.71	1.801	1.68	1.68
4	3	1	1	1	9.356	206.201	9.71039584290387E-47	2.832	1.71	1.801	1.68	1.68
4	1	1	1	1	9.414	211.171	9.71039584290387E-47	2.832	1.71	1.801	1.68	1.68
3	6	1	1	1	13.87	162.256	9.71039584290387E-47	2.832	1.71	1.801	1.68	1.68
3	1	1	2	1	295.188	34.597	9.71039584290387E-47	2.832	1.71	1.801	1.68	1.68
4	8	10	2	1	195.14	39.411	9.71039584290387E-47	2.832	1.71	1.801	1.68	1.68
4	10	4	1	1	6.892	195.269	9.71039584290387E-47	2.832	1.71	1.801	1.68	1.68
3	10	10	2	1	203.428	64.539	9.71039584290387E-47	2.832	1.71	1.801	1.68	1.68
5	3	2	2	1	344.76	92.157	9.71039584290387E-47	2.832	1.71	1.801	1.68	1.68
2	3	1	2	1	272.344	68.949	9.71039584290387E-47	2.832	1.71	1.801	1.68	1.68
3	1	1	1	1	7.566	171.701	9.71039584290387E-47	2.832	1.71	1.801	1.68	1.68
3	1	1	2	1	365.306	68.339	9.71039584290387E-47	2.832	1.71	1.801	1.68	1.68
3	1	1	2	1	358.686	80.269	9.71039584290387E-47	2.832	1.71	1.801	1.68	1.68
3	1	1	1	1	8.646	171.815	9.71039584290387E-47	2.832	1.71	1.801	1.68	1.68

Figura 3: Tela da aplicação que mostra a evolução do aprendizado da rede, assim como a classificação do transformadores.

#### 4.2. Resultado dos testes da rede

Depois da rede ter sido treinada e depois de definido qual neurônio irá representar cada estado, partiu-se para os testes na rede para medirmos a eficiência da mesma.

Primeira rede testada (100 interações)

Das 20 amostras de testes, 18 amostras apontaram para o resultado correto, representando uma eficiência de 90%.

Segunda rede testada (200 interações)

Das 20 amostras de testes, 17 amostras apontaram para o resultado correto, representando uma eficiência de 85%.

Terceira rede testada (500 interações)

Das 20 amostras de testes, 19 amostras apontaram para o resultado correto, representando uma eficiência de 95%.

## 5. CONCLUSÃO

1. Foi observado que com a utilização do algoritmo de Kohonen, aplicado a uma base de dados histórica foi possível caracterizar ou agrupar a situação dos transformadores da companhia, com isso a manutenção destes equipamentos passou a ser feita com base em critérios apontados pela própria rede de Kohonen.
2. Para o sucesso da rede, ou um alto grau de acerto dos exemplos apresentados, foi atestado que o ajuste dos parâmetros da rede também é essencial.
3. A análise dos dados que devem ser apresentados à rede também é de suma importância, uma vez que a intenção é criar um sistema especializado em um determinado problema.
4. Por fim, verificou-se que o objetivo principal do estudo foi atingido que era utilizar com uma boa eficiência as redes neurais com modelagem Kohonen para indicar a possível queima de transformadores de distribuição queimados de uma concessionária.

Como contribuição foi desenvolvido um aplicativo que faz uso do algoritmo de Kohonen, sendo demonstrado neste software as características deste algoritmo, que inicialmente possui a capacidade de diagnosticar problema de acordo com dados previamente analisados no banco de dados da concessionária CELPA. Porém houve a preocupação em demonstrar o uso deste algoritmo de forma que também possa ser utilizado para outros problemas, para isso basta mudar a base de dados apresentada ao mesmo.

## 6. REFERÊNCIAS BIBLIOGRÁFICAS

..... BARBALHO, J. M. & Neto, A. D. & Costa, J. A. F. & Netto, M. L. *Hierarchical SOM applied to Image Compression*, IJCNN., 2001.

..... BITTENCOURT, Guilherme. *Inteligência artificial ferramentas e teorias*. Florianópolis, Ed. UFSC, 2001.

..... HAYKIN, Simon. *Redes Neurais Princípios E Prática*. São Paulo, Ed. Bookman, 2002.

..... Kohonen, T. *Self-Organization of Very Large Document*. In: Proc. the 8th ICANN, Skoevde, Sweden, pp.65-74. 1988;

..... RUSSELL, Stuart J; NORVIG, Peter. *Inteligência artificial teoria e prática*. Rio de Janeiro, Ed. Campus, 2004.