

## **ESTUDO DA QUALIDADE DO AR DO ESTADO DE SÃO PAULO POR MEIO DE MAPAS AUTO-ORGANIZÁVEIS DE KOHONEN**

**Alessandro Martins Alves**

Universidade Federal Fluminense  
Rua Passo da Pátria 156, São domingos, Niterói  
[alessandro.martinsalves@yahoo.com.br](mailto:alessandro.martinsalves@yahoo.com.br)

**Thiago Graça Ramos**

Universidade Federal Fluminense  
Rua Passo da Pátria 156, São domingos, Niterói  
[tgramos@globocom.com](mailto:tgramos@globocom.com)

**João Carlos C.B Soares de Mello**

Universidade Federal Fluminense  
Rua Passo da Pátria 156, São domingos, Niterói  
[jcsmello@pesquisador.cnpq.br](mailto:jcsmello@pesquisador.cnpq.br)

**Luiz Biondi Neto**

Universidade do Estado do Rio de Janeiro  
Avenida Maracanã, Rio de Janeiro  
[luizbiondi@terra.com.br](mailto:luizbiondi@terra.com.br)

### **Resumo**

O presente trabalho utiliza mapas auto-organizáveis de Kohonen para fazer uma análise da qualidade do ar no estado de São Paulo, utilizando-se dos dados divulgados pela companhia ambiental do Estado de São Paulo. O artigo utiliza a rede neural de Kohonen para agrupar os municípios em grupos que possuem níveis de poluição homogêneos, ou seja, que possuem um perfil semelhante de distribuição de poluentes na atmosfera. A utilização da rede de Kohonen ajuda na determinação de uma arquitetura mínima, capaz de representar o conjunto de dados. O artigo identificou grupos de municípios que, apesar de não serem próximos fisicamente, pertencem ao mesmo grupo de poluição.

**Palavras-Chaves:** Redes Neuras de Kohonen, Agrupamentos, Poluição do ar

### **Abstract**

The present study uses Kohonen self-organizing maps of to analyze the air quality in the state of São Paulo. The data source was the CETESB - Environmental Company of São Paulo. We use the Kohonen neural network to group the cities into groups that have homogeneous levels of pollution, i.e. that have a similar profile of distribution of pollutants in the atmosphere. The use of Kohonen neural network helps determine a minimal architecture, capable of representing the data set. The article identified groups of municipalities which, although not physically close, belong to the same group of pollution."

**Keywords:** Kohonen Neural Networks, Clusters, Air Pollution

## 1. INTRODUÇÃO

A poluição do ar é um dos grandes problemas de saúde pública, afetando a saúde dos seres humanos, dos animais e das plantas. Nas cidades industriais, a emissão de gases tóxicos e partículas pelas indústrias, somada à poluição provocada pela circulação de veículos, gera problemas para a saúde da população.

Segundo Livingstone (2002) e Berend (2006), um dos primeiros grandes episódios de poluição do ar ocorreu em 1952, em Londres. Esse episódio trouxe conseqüências dramáticas para a saúde da população. Em dezembro de 1952, uma combinação de fatores prejudicou a dispersão da poluição e fez com que a cidade de Londres ficasse envolta numa densa nuvem de fumaça. Os fatores que prejudicaram a dispersão da poluição foram: temperaturas baixas, emissão de gases provenientes de veículos automotores e aumento do uso de lareiras domésticas.

Após o aumento da mortalidade em Londres, diversos estudos foram feitos com o intuito de demonstrar a relação entre os problemas respiratórios e as diversas concentrações de poluentes no ar.

Dentre os estudos que relacionam os efeitos da poluição do ar com a qualidade de vida da população afetada, pode-se destacar (Ribeiro et al., 1976; Fernícola & Azevedo, 1981; Fischer, 1986; Landsdown & Yule, 1986; Eco, 1989; Hofmeister, 1991; Hofmeister et al., 1992), e, em situações extremas, a elevada poluição do ar pode levar a um aumento da mortalidade nas áreas de maior concentração de poluentes (Duchiade & Beltrão, 1992; Lichtenfels et al., 1993; Saldiva, 1993; Kwang-Soo et al., 1997).

Medeiros e Gouveia (2005) fizeram um trabalho relacionando a poluição do ar com o baixo peso ao nascer, no município de São Paulo e confirmaram que a exposição materna à poluição do ar no primeiro trimestre de gravidez pode contribuir para um menor ganho de peso do feto.

Segundo relatório da CETESB (2009), os poluentes que mais influenciam na qualidade do ar são: monóxido de carbono, dióxido de enxofre, material particulado, ozônio, além do dióxido de nitrogênio. As características desses principais poluentes serão detalhadas no capítulo seguinte, assim como suas origens, efeitos no meio ambiente e impacto sobre a saúde.

O presente trabalho faz uma análise da poluição do ar em alguns municípios do Estado de São Paulo, com base nos dados publicados pelo CETESB.

A CETESB – Companhia Ambiental do Estado de São Paulo - publica anualmente um relatório de qualidade ambiental, além de outros relatórios relacionados à gestão da qualidade ambiental do Estado de São Paulo. Esse diagnóstico da qualidade ambiental é uma importante ferramenta no planejamento de novos programas de qualidade ambiental.

O objetivo do artigo é organizar os municípios do Estado de São Paulo em grupos, de acordo com o tipo de poluição apresentada por cada um dos municípios. Para que o objetivo seja alcançado, serão utilizados os mapas auto-organizáveis de Kohonen, que visam agrupar os dados de entrada que são semelhantes entre si, formando classes ou agrupamentos denominados clusters.

Este método já foi utilizado por diversos autores e em diversas áreas de interesse, como em Ângulo-Meza et al (2011) onde os mapas foram utilizados com o intuito de criar cluster para avaliar a educação no Estado do Rio de Janeiro; e Biondi Neto et al (2007), onde foi feito um mapeamento do consumo elétrico no estado do Rio de Janeiro.

Diante do que foi exposto, o artigo apresentará o objetivo na próxima sessão, com uma breve descrição sobre os poluentes pesquisados pelo CETESB. Em seguida tem-se uma breve exposição sobre redes neurais, com foco nos mapas auto-organizáveis de Kohonen. Por fim, será feita uma breve explicação da modelagem assim como a análise dos resultados, conclusões e trabalhos futuros.

## 2. OBJETIVO

O presente artigo tem como objetivo organizar os municípios do Estado de São Paulo em grupos, de acordo com o tipo de poluente presente neles.

Para que o objetivo seja alcançado, serão utilizados os mapas auto-organizáveis de Kohonen, que visam agrupar os dados de entrada que são semelhantes entre si formando classes ou agrupamentos denominados clusters. O método visa agrupar municípios que apresentam altos índices da mesma substância poluente.

## 3. POLUENTES

O nível de poluição atmosférica é determinado pela quantificação das substâncias poluentes presentes no ar. Conforme a resolução do CONAMA No 3 de 28/06/1990, considera-se poluente atmosférico “qualquer forma de matéria ou energia com intensidade e em quantidade, concentração, tempo ou características em desacordo com os níveis estabelecidos, e que tornem ou possam tomar o ar impróprio, nocivo ou ofensivo à saúde, inconveniente ao bem-estar público, danoso aos materiais, à fauna e à flora ou prejudicial à segurança, ao uso e gozo da propriedade e às atividades normais da comunidade”.

A análise dos principais poluentes encontra-se na tabela 3.1

Tabela 3.1–Características, fontes e efeitos gerais ao meio ambiente dos principais poluentes

| <b>Poluente</b>                          | <b>Característica</b>  | <b>Fontes Principais</b>  | <b>Efeitos Gerais ao meio ambiente</b>   |
|--|--|---|--|
| Partículas Inaláveis (MP <sub>10</sub> ) | Partículas de material sólido ou líquido que ficam suspensas no ar. Tamanho < 10 micra                                 | Processos de combustão (indústria e veículos), aerossol secundário (formado na atmosfera)   | Danos à vegetação, deterioração da visibilidade e contaminação do solo             |
| Dióxido de enxofre (SO <sub>2</sub> )    | Gás incolor, com forte odor, semelhante ao gás produzido na queima de palitos de fósforos.                             | Processos que utilizam queima de óleo combustível, refinaria de petróleo, veículos a diesel, produção de polpa e papel, fertilizantes                 | Pode levar à formação de chuva ácida, causar corrosão aos materiais e a vegetação  |
| Dióxido de nitrogênio (NO <sub>2</sub> ) | Gás marrom avermelhado, com odor forte. Pode levar à formação de ácido nítrico, nitratos e compostos orgânicos tóxicos | Processos de combustão envolvendo veículos automotores, processos industriais, usinas térmicas que utilizam óleo ou gás, incinerações                 | Pode levar à formação de chuva ácida, danos à vegetação e à colheita               |
| Monóxido de carbono (CO)                 | Gás incolor, inodoro e insípido  | Combustão incompleta em veículos automotores  |  |
| Ozônio (O <sub>3</sub> )                 | Gás incolor, inodoro nas concentrações ambientais e o principal componente da névoa fotoquímica                        | Não é emitido diretamente na atmosfera. É produzido fotoquimicamente pela radiação solar sobre os óxidos de nitrogênio e compostos orgânicos voláteis | Danos às colheitas, à vegetação natural, plantações agrícolas; plantas ornamentais |

Fonte: CETESB

Como visto na tabela 3.1, os poluentes do ar originam-se principalmente da combustão incompleta de combustíveis fósseis, para fins de transporte, aquecimento e produção industrial.

O nosso sistema de transporte atual se baseia na queima de combustíveis, conseqüentemente, a poluição do ar é um subproduto. Estas fontes de transporte incluem automóveis, ônibus, caminhões, aviões, equipamentos de fazenda, trens, navios, etc. Devido ao grande número, os automóveis são a fonte principal desta categoria.


#### 4. REDES NEURAIS ARTIFICIAIS

As Redes Neurais Artificiais constituem-se em modelos computacionais paralelos baseados numa unidade atômica, o neurônio. Em geral, estes modelos possuem inspiração neurobiológica, porém, na prática, eles são algoritmos computacionais representados de maneira bastante elementar, o mecanismo de funcionamento cerebral. Atualmente, existe uma extensa variedade de redes neurais artificiais (RNAs) disponíveis.

Na figura 4.1, pode-se perceber que cada neurônio  $J$  possui as seguintes características:

- Vetor de dados de entrada;  $X_k = (\xi_1, \xi_2, \dots, \xi_n)^T$
- Ativação Interna  $J$ ;
- Função de Ativação  $f(J)$ ;
- Pesos Sinápticos;  $w_j = (w_{j1}, \dots, w_{jd})^T$

FIGURA 4.1 – Modelo básico de um neurônio  $j$  com entrada  $x_k$ , pesos sinápticos  $w_j$



Este seria o modelo básico de Redes Neurais Artificiais (RNA); podem existir outras formas de RNA desde que uma das seguintes características seja alterada:

- Arquitetura da rede neural;
- Características dos neurônios envolvidos no processo;
- Treinamento utilizado para absorção do conhecimento;

Haykin (2001) cita que as redes neurais artificiais apresentam como vantagens as características de adaptabilidade, generalização e tolerância a ruídos. Estas características são extremamente importantes quando aplicadas a problemas geográficos, dada a natureza complexa e ruidosa dos mesmos.

Já Kohonen (2001) propõe dividir as redes neurais em três categorias:

- Redes de transferência de sinal;
- Redes de transferência de estados;
- Redes competitivas;

Nas redes de transferência de sinais a saída da rede dependerá, única e exclusivamente, do valor de entrada. Estas redes são usadas para transformação de sinais. São exemplos deste tipo de rede aquelas “alimentadas adiante”, como os Perceptrons de Múltiplas Camadas - Multi-Layer Perceptron-MLP (Rumelhart et al., 1986) e as redes de função de base radial - Radial Basis Function-RBF (Bishop, 1995). Essas redes são usadas como identificadores e classificadores de padrões, controle, avaliação de dados de entrada; por outro lado, as redes de transferência de estado têm como base os efeitos de relaxação.

A retroalimentação e a não-linearidade são tal que garantem que o estado de atividade rapidamente convirja para um de seus valores estáveis, ou seja, os valores de entrada acionam o estado inicial de atividade, a rede então inicia o processamento até chegar ao estado final. São exemplos deste tipo de rede as redes de Hopfield (Fausett, 1994) e a

máquina de Boltzman (Haykin, 2001). As principais aplicações destas redes são como função de memória associativa e problemas de otimização, embora também sejam usadas no reconhecimento de padrões.

As redes de aprendizagem competitiva estão baseadas no processo competitivo de aprendizagem entre suas unidades. Uma das principais aplicações destas redes é a descoberta de agrupamentos de dados. Estão incluídas nesta categoria as redes SOM (Kohonen, 2001) e ART - Adaptive Resonance Theory (Fausett, 1994). A aprendizagem competitiva é um processo adaptativo onde os neurônios, numa rede neural artificial, tornam-se gradualmente sensíveis a diferentes categorias de entrada e a conjuntos de amostras num domínio específico do espaço de entrada.

Como o objetivo do trabalho é verificar a qualidade do ar e quais fatores poluem mais em cada região, os mapas auto-organizáveis têm papel fundamental no artigo e por isso será apresentado uma explicação maior sobre este tópico.

#### 4.1. MAPAS AUTO-ORGANIZÁVEIS (SOM)

As arquiteturas auto-organizáveis, como propostas por Kohonen (1982), geram mapeamentos de um espaço de dimensão elevada em estruturas cuja dimensão topológica é inferior à original. Estes mapeamentos são capazes de preservar as relações de vizinhança dos dados de entrada. Isto os torna interessantes para aplicações em diversas áreas, como reconhecimento de voz, análise exploratória de dados (KASKI, 1995; 1997), otimização combinatória e mapeamento da poluição numa determinada região, como será feito no artigo.

O fato de que mapeamentos similares podem ser encontrados em diversas áreas do cérebro humano e de outros animais indica que a preservação da topologia é um princípio importante pelo menos em sistemas de processamento de sinais. A redução de dimensão pode acarretar uma perda de informação (a qual se procura minimizar) ou então pode levar a uma transformação topológica da informação original (de modo a explicitar relações não evidenciadas até então). Em ambos os casos, o que se procura é preparar a informação disponível para um processamento posterior, eliminando todo tipo de redundância e apresentando a informação de forma que ela possa ser diretamente manipulada.

Os mapas auto-organizáveis de Kohonen fazem parte de um grupo de redes neurais chamado redes baseadas em modelos de competição, ou simplesmente redes competitivas (FAUSETT, 1994). Estas redes combinam competição com uma forma de aprendizagem para fazer os ajustes de seus pesos.

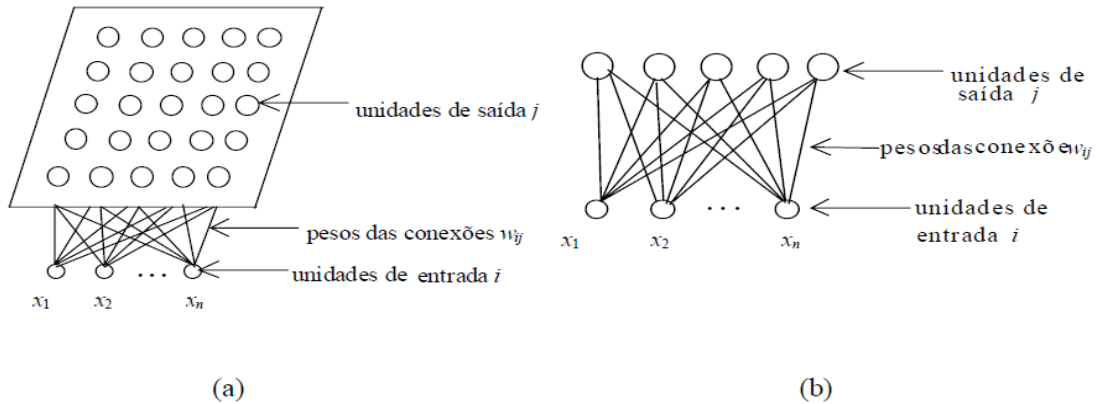
Outra característica importante deste tipo de rede é que elas utilizam treinamento não-supervisionado, onde a rede busca encontrar similaridades baseando-se apenas nos padrões de entrada. O principal objetivo dos mapas auto-organizáveis de Kohonen é agrupar os dados de entrada que são semelhantes entre si formando classes ou agrupamentos denominados clusters.

Em uma rede classificadora há uma unidade de entrada para cada componente do vetor de entrada. Cada unidade de saída representa um cluster, o que limita a quantidade de clusters ao número de saídas. Durante o treinamento a rede determina a unidade de saída que melhor

A Figura 4.1.1 apresenta arquiteturas típicas de um mapa auto-organizável de Kohonen, considerando configurações de vizinhança unidimensional (b) e bidimensional (a), embora dimensões mais elevadas possam ser consideradas. Além disso, dada a dimensão, a quantidade de unidades ou neurônios de saída pode ser arbitrada e mantida fixa, ou então definida automaticamente pelo algoritmo de treinamento, como será descrito mais adiante para o caso de vizinhanças unidimensionais.

A quantidade de elementos de entrada depende do banco de dados a ser utilizado no treinamento da rede. O grid de saída pode ser de várias dimensões, com quantidade de elementos variável.

Figura 4.1.1 – Tipos de Arquitetura



Kaski (1997) apresenta uma forma padrão para que as redes sejam treinadas e para isso vale seguir o passo a passo a seguir:

1. Inicialização e definição dos parâmetros a serem utilizados;
  - a. Inicialize os pesos  $W_{ij}$ ;
  - b. Defina os parâmetros de vizinhança;
  - c. Defina os parâmetros de aprendizagem;
2. Enquanto a condição de parada for falsa, siga os passos abaixo:
  - a. Para cada  $j$  calcule:

$$D(j) = \arg \min \left\{ \|w_j - x_j\| \right\}$$

- i. Encontre o índice  $J$  tal que  $D(J)$  seja mínimo;
- ii.  $\forall j \in N_c$  de  $J$ , e  $\forall i$ :

$$w_{ij}(\text{novo}) = w_{ij}(\text{antigo}) + \alpha [x_i - w_{ij}(\text{antigo})]$$

- b. Atualize a taxa de aprendizagem;
- c. Reduza o raio de vizinhança;

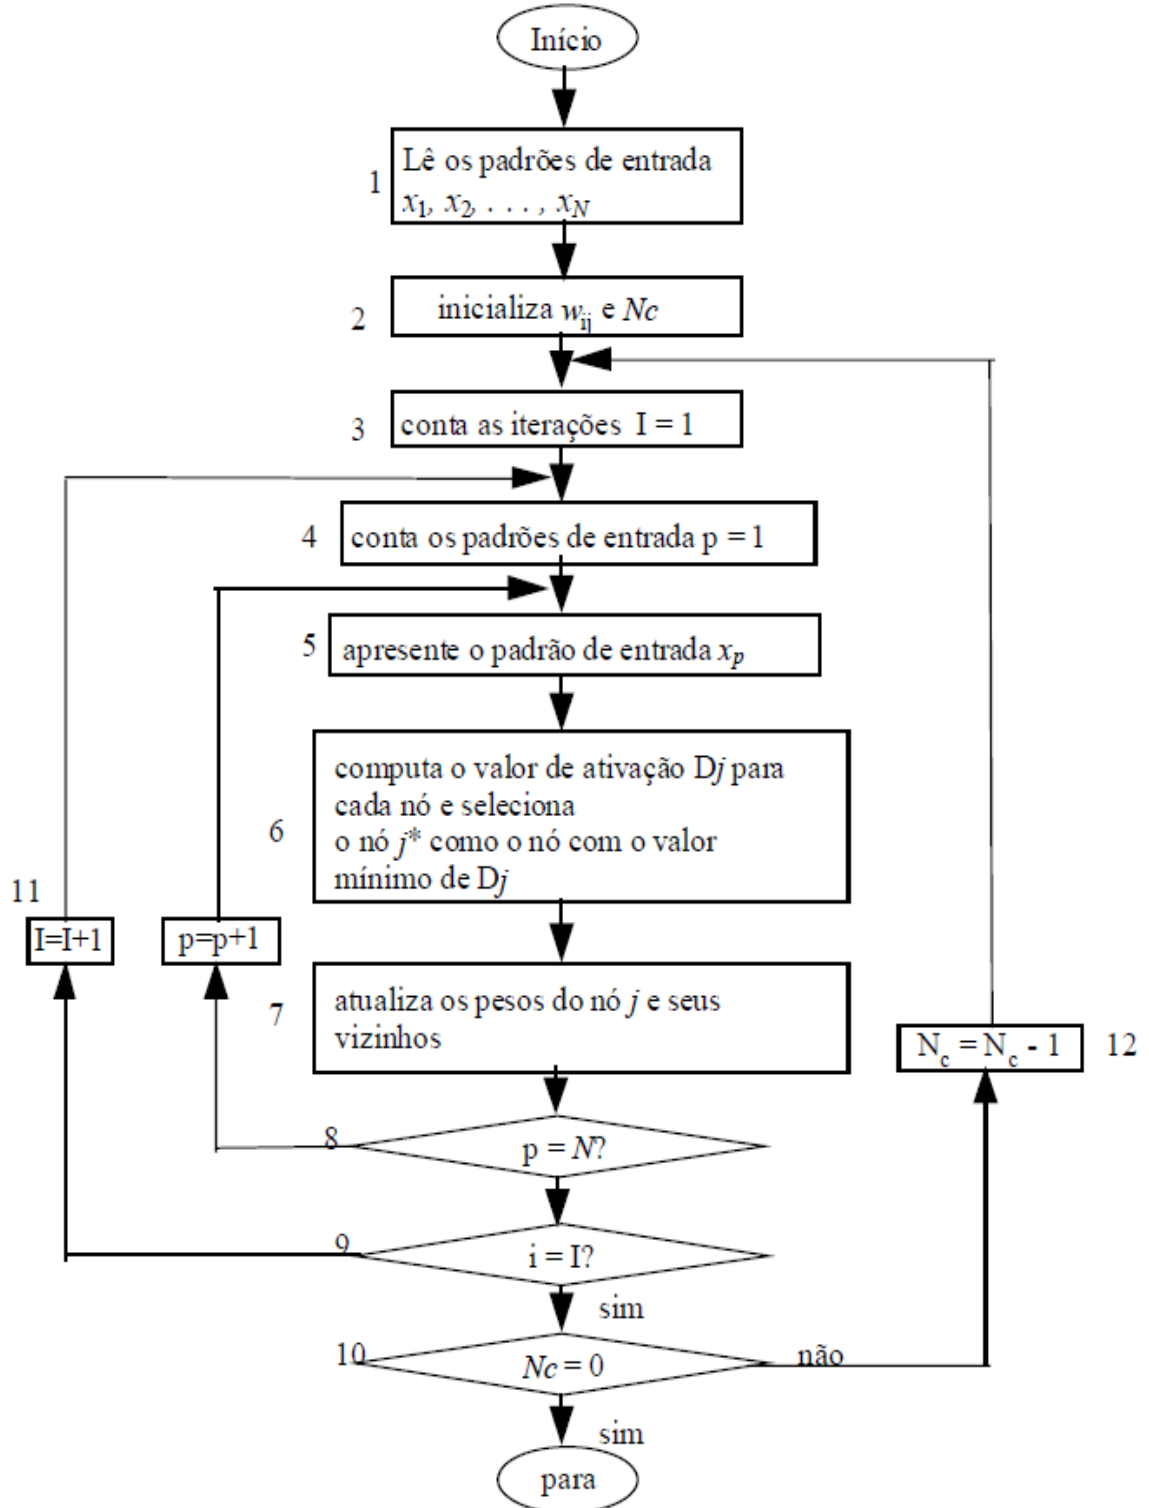
Como a taxa de aprendizagem decresce com o passar do tempo, o mapa será formado em duas fases: formação inicial da ordem correta e a convergência final. O fluxograma 4.1.2 mostra como funciona toda a fase de treinamento de um mapa auto-organizável (SOM).

No processo de treinamento descrito pelo fluxograma 4.1.2,  $N_c$  é decrementado de 1 após um determinado número de iterações bloco 12 da figura 4.1.2 até que  $N_c$  seja igual a zero. Aqui, diz-se que ocorreu uma iteração quando o vetor de padrões tiver sido apresentado uma vez. O procedimento detalhado dentro de uma iteração é descrito como segue.

Depois de especificado os pesos iniciais das conexões, o valor de ativação de cada nó de saída pode ser computado. O nó  $J$  com o máximo valor de ativação é selecionado como a unidade vencedora. Isto é o que o algoritmo de treinamento faz no bloco 6 da Figura 4.1.2.

No bloco 7, os pesos das conexões para o nó  $J$  e todos os nós em sua vizinhança definidos por  $NE_j$  como mostrado na Figura 4.1.2 são atualizados. Os procedimentos acima são repetidos para cada padrão de entrada. Quando todas as  $N$  amostras de entrada tiverem sido apresentadas, dizemos que uma iteração está completa.

Figura 4.1.2 – Fluxograma de treinamento



## 5. ANÁLISE DOS RESULTADOS E MODELAGEM

Foram testadas diferentes organizações dos neurônios combinações com o intuito de encontrar a melhor forma de organizar os municípios dentro através das variáveis (10x10, 8x8, 6x6, 7x5). Foram selecionados dois modelos, 10x10 e 8x8, que, na opinião dos autores, foram os que melhor segmentaram os dados.

Para a análise de resultados, foi coletada a quantidade de 6 tipos de poluentes diferentes, presentes no ar de 20 municípios do estado de São Paulo. Para que não tivéssemos que inserir nenhum tipo de dado; foram selecionados apenas os municípios que possuíam dados para os 6 tipos de poluentes escolhidos no mês de outubro de 2010. A tabela 5.1 apresenta os municípios e quantidade de cada poluente.

Pode-se observar que para alguns poluentes foram encontrados municípios que se destacam por ter um alto índice. Para partículas inaláveis, o município de Presidente Prudente apresenta uma presença bastante considerável quando comparado aos demais municípios.

Com relação aos poluentes Monóxido de Nitrogênio, Dióxido de Nitrogênio e Óxido de Nitrogênio, destaca-se Osasco, que pode apresentar estes altos níveis devido ao tipo de indústrias presentes em sua região, pois nesta região existe uma forte presença de metalúrgicas.

Tabela 5.1 Quantidade de cada poluente presente no ar de cada município

|                       | Partículas Inaláveis | Monóxido de Nitrogênio | Dióxido de Nitrogênio | Óxido de Nitrogênio | Ozônio | Velocidade do Vento |
|-----------------------|----------------------|------------------------|-----------------------|---------------------|--------|---------------------|
| Araraquara            | 36                   | 16                     | 52                    | 39                  | 103    | 2.8                 |
| Bauru                 | 30                   | 24                     | 64                    | 50                  | 92     | 2.7                 |
| Catanduva             | 38                   | 15                     | 46                    | 34                  | 104    | 2.6                 |
| Cubatão_Centro        | 31                   | 110                    | 61                    | 115                 | 84     | 1.2                 |
| Cubatão-Vale Mogi     | 51                   | 89                     | 56                    | 140                 | 57     | 2.4                 |
| Ilbirapuera           | 34                   | 29                     | 61                    | 54                  | 115    | 1.6                 |
| Jundiaí               | 32                   | 34                     | 66                    | 56                  | 94     | 2.8                 |
| Marília               | 23                   | 10                     | 42                    | 28                  | 96     | 3.1                 |
| Osasco                | 41                   | 200                    | 92                    | 199                 | 98     | 2.2                 |
| Paulínia              | 34                   | 18                     | 48                    | 35                  | 128    | 2.5                 |
| Paulínia Sul          | 51                   | 30                     | 56                    | 49                  | 120    | 1.8                 |
| Piracicaba            | 36                   | 28                     | 57                    | 44                  | 114    | 2.6                 |
| Presidente Prudente   | 98                   | 21                     | 54                    | 45                  | 90     | 2.3                 |
| Ribeirão Preto        | 37                   | 11                     | 47                    | 32                  | 97     | 2.3                 |
| São José do Rio Preto | 40                   | 27                     | 56                    | 49                  | 110    | 2.4                 |
| Sorocaba              | 27                   | 27                     | 45                    | 41                  | 81     | 1.7                 |

O município de Marília se destaca pela alta velocidade do seu vento, o que pode ser um bom indicador para os seus baixos índices dos poluentes escolhidos, visto que uma cidade com velocidades do vento alto, acaba por dispersar mais rapidamente os poluentes presentes no ar.

Estes dados foram inseridos nas Redes de Kohonen com o objetivo de encontrar regiões que tenham as mesmas características de poluição do ar. Para isso foram feitas algumas tentativas visando encontrar a melhor rede. A primeira tentativa foi utilizar uma rede 10x10, onde existem 100 neurônios de ativação e o resultado pode ser observado na Figura 5.2. As variáveis dispostas no mapa seguem a ordem das colunas da tabela 5.1, logo a “variable 1” significa partículas inaláveis, “variable 2” é o Monóxido de Nitrogênio e assim sucessivamente.

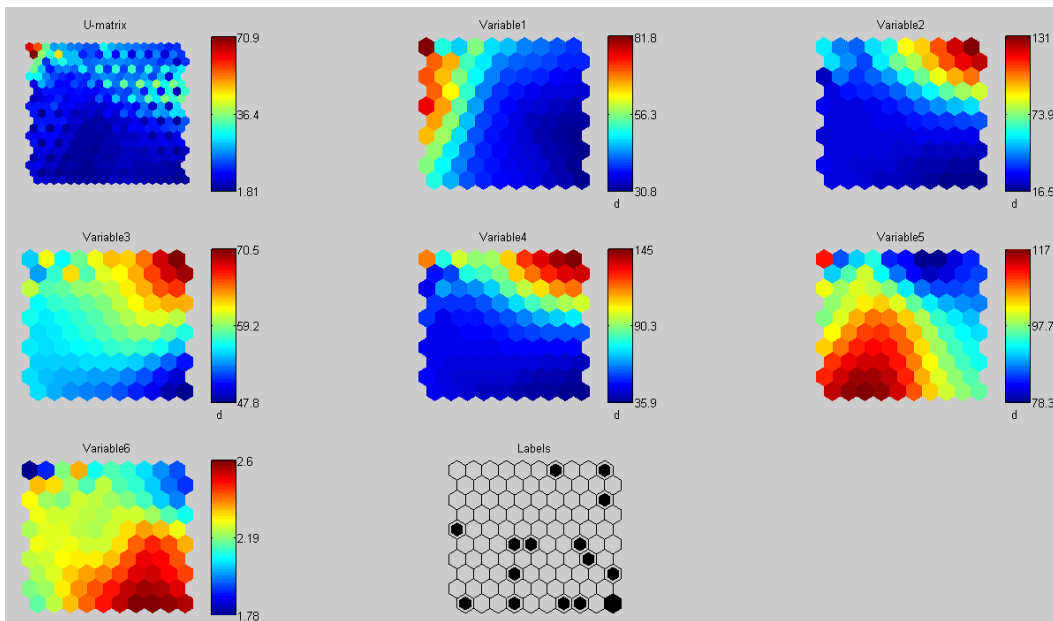
Para identificar melhor os segmentos, é necessário ver a ativação dos neurônios e conforme o neurônio é ativado, ele fica mais vermelho, vide escala ao lado de cada gráfico.

A contagem dos neurônios é sempre feito da esquerda para a direita a partir da primeira linha, no caso 8x8, o primeiro neurônio da primeira linha é o 1 e o último é o 8°.

A figura abaixo ilustra a rede de kohonen com 100 neuronios, dispostos em uma matriz 10 x 10.

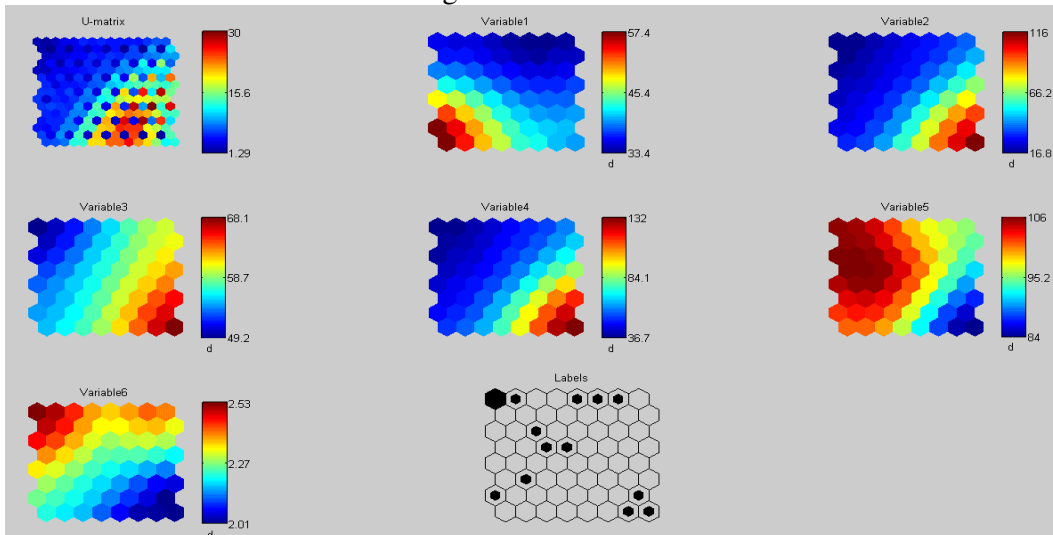


Figura 5.2 – Rede de Kohonen 10 x 10



Como o mapa da figura 5.2 não definiu clusters tão homogêneos, foi tentada uma diminuição no número de neurônios com o intuito de obter uma melhor ativação, visto que, no mapa com 100 neurônios, ocorreu um grande espalhamento dos neurônios mais ativados. Por isso será apresentado na figura 5.3 a rede com 64 neurônios organizados de forma quadrada com tamanho 8x8.

Figura 5.3 - Rede de Kohonen 8x8



Ao observar a Figura 5.3 percebe-se que existem 5 clusters mais bem definidos, quando comparado a rede 10x10. Pode-se perceber também que, para os neurônios 1,2 observa-se uma forte presença da velocidade do vento, enquanto que para as partículas inaláveis encontramos destaque no neurônio 49.

Em relação aos elementos que possuem Nitrogênio, os neurônios 56, 63 e 64 foram os mais ativados. O ozônio, que é uma variável onde todos os municípios apresentaram mais

ou menos os mesmos níveis, ficou com uma presença bastante forte nos neurônios 19, 27 e 28. O último cluster identificado são os neurônios 5, 6 e 7, onde as partículas inaláveis apresentam um baixo índice deste poluente.

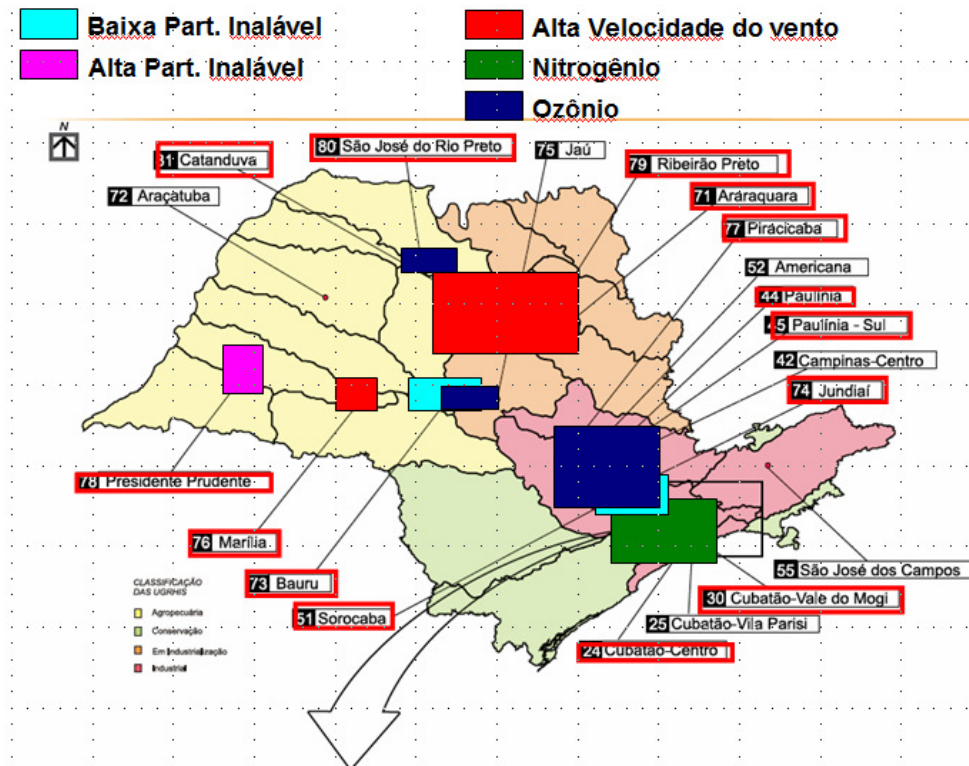
Tabela 5.4 – Destaque segundo os clusters

|                       | Partículas Inaláveis | Monóxido de Nitrogênio | Dióxido de Nitrogênio | Óxido de Nitrogênio | Ozônio | Velocidade do Vento |
|-----------------------|----------------------|------------------------|-----------------------|---------------------|--------|---------------------|
| Araraquara            | 36                   | 16                     | 52                    | 39                  | 103    | 2.8                 |
| Bauru                 | 30                   | 24                     | 64                    | 50                  | 92     | 2.7                 |
| Catanduva             | 38                   | 15                     | 46                    | 34                  | 104    | 2.6                 |
| Cubatão_Centro        | 31                   | 110                    | 61                    | 115                 | 84     | 1.2                 |
| Cubatão-Vale Mogi     | 51                   | 89                     | 56                    | 140                 | 57     | 2.4                 |
| Ibirapuera            | 34                   |                        |                       |                     | 115    | 1.6                 |
| Jundiaí               | 32                   | 34                     | 66                    | 56                  | 94     | 2.8                 |
| Marília               | 23                   | 10                     | 42                    | 28                  | 96     | 3.1                 |
| Osasco                | 41                   | 200                    | 92                    | 199                 | 98     | 2.2                 |
| Paulínia              | 34                   | 18                     | 48                    | 35                  | 128    | 2.5                 |
| Paulínia Sul          | 51                   | 30                     | 56                    | 49                  | 120    | 1.8                 |
| Piracicaba            | 36                   | 28                     | 57                    | 44                  | 114    | 2.6                 |
| Presidente Prudente   | 98                   | 21                     | 54                    | 45                  | 90     | 2.3                 |
| Ribeirão Preto        | 37                   | 11                     | 47                    | 32                  | 97     | 2.3                 |
| São José do Rio Preto | 40                   | 27                     | 56                    | 49                  | 110    | 2.4                 |
| Sorocaba              | 27                   | 27                     | 45                    | 41                  | 81     | 1.7                 |

Ao observar a tabela 5.4, pode-se perceber onde existem valores mais acentuados de poluição que justificam os agrupamentos feitos pelos Mapas Kohonen. Percebe-se que os poluentes com Nitrogênio tiveram uma grande presença em 3 regiões (Cubatão – Centro, Cubatão – Vale Mogi e Osasco), isto se justifica pelo tipo de indústria localizado na região.

O município de Marília se destacou com a alta velocidade de seus ventos e podemos perceber que lá também não tem um alto nível de nenhum poluente, o que justifica a hipótese de que cidade onde a velocidade média dos ventos é alta, os poluentes se dispersam mais facilmente.

Figura 5.5 – Alocação dos segmentos ao mapa do estado de São Paulo



A figura 5.5 mostra as regiões em que os municípios foram agrupados. A região verde, onde os poluentes se caracterizam por ter nitrogênio é justamente a região chamada de ABCDOG, que possui um número bastante grande de metalúrgica e fabrica de veículos, ocasionando este tipo de poluição.

## 6. CONCLUSÕES E TRABALHOS FUTUROS

O presente trabalho visava organizar clusters segundo os níveis de poluição de alguns municípios do estado de São Paulo. Ao final, foram encontrados 5 grupos homogêneos entre si que possuíam características que os discriminavam em relação aos demais grupos.

Pode-se perceber que algumas regiões apresentaram elevados índices de alguns poluentes, em especial o nitrogênio, como a região do ABCDOG, em função do tipo de indústria presente na mesma.

Mostrou-se que nem sempre a proximidade geográfica determina padrões semelhantes de concentração de poluentes.

Com base nesses segmentos, foi possível identificar as áreas com concentrações semelhantes em termos de poluentes, tornando possível a realização de um mesmo trabalho por parte do governo, com o intuito de reduzir a emissão desse tipo de poluente, evitando assim que a população sofra maiores danos.

Para trabalhos futuros, deseja-se incluir monóxido de carbono e o dióxido de enxofre, que são dois poluentes que agridem muito o ser humano e que não foram utilizados no presente trabalho em função da pouca quantidade de dados disponíveis.

## 7. REFERÊNCIAS BIBLIOGRÁFICAS

- [1] ANGULO MEZA, L, BIONDI NETO, L., BRANDÃO, L.C., ANDRADE, F.V.S., SOARES DE MELLO, J.C.C.B., COELHO, P.H.G. (2011). Modelling with Self-Organising Maps and Data Envelopment Analysis: a Case Study in Educational Evaluation. In: Josphat Igadwa Mwasiagi. (Org.). Self Organizing Maps - Applications and Novel Algorithm Design. : InTech, 2011, v. 1, p. 71-88.

- [2] **BEREND, IVAN T.** *An Economic History of Twentieth-Century Europe*. [S.l.]: Cambridge University Press, 2006. p. 312
- [3] **BIONDI NETO, , COELHO, P.H.G. L., , SOARES DE MELLO, J.C.C.B. ANGULO MEZA, L.** (2007). Self-organizing maps for classification of the Rio de Janeiro state cities based on electrical energy consumption. ICEIS 2007 - 9th International Conference on Enterprise Information Systems, Proceedings, AIDSS, pp. 447-450.
- [4] **BISHOP, M. P.** An Introduction to the Kalman Filter. University of North Carolina – Chapel Hill, 1992.
- [5] **CETESB – Companhia Ambiental do Estado de São Paulo – Série Relatórios – Qualidade do ar no Estado de São Paulo, 2009.**
- [6] **DUCHIADE, M. P.** (1992). Poluição do ar e doenças respiratórias: uma revisão. Cadernos de Saúde Pública, 8:311-330
- [7] **FAUSETT, L. V. ,** Fundamentals neural networks: architectures, algorithms and applications. Prentice Hall, Upper saddle River, NJ 07458, 1992.
- [8] **FERNÍCOLA, N. A. G. C. & AZEVEDO, F. A.** Contribuição dos Estudos da Toxicologia Ambiental para a Saúde Humana. XI Congresso Brasileiro de Engenharia Sanitária e Ambiental, Resumos. Fortaleza: Associação Brasileira de Engenharia Sanitária e Ambiental, 1981.
- [9] **FISCHER, F. M.** Avaliação da Função Pulmonar em Pré-Escolares Vivendo em Diferentes Áreas do Município de Cubatão. São Paulo: Departamento de Saúde Ambiental, Universidade de São Paulo, 1986.
- [10] **HAYKIN, S.** Kalman Filtering and Neural Networks, John Wiley & Sons, Inc. ISBNs: 0-471-36998-5 (Hardback), 2001.
- [11] **HOFMEISTER, V. A.** Efeitos da Poluição do Ar sobre a Função Pulmonar: Um Estudo de Coorte em Crianças de Cubatão. Tese de Doutorado, São Paulo: Faculdade de Saúde Pública, Universidade de São Paulo, 1991.
- [12] **HOFMEISTER, V. A.; FISCHER, F. M.; NOGUEIRA, D. P. & ROMIEU, I.** (1992) Case-study: effects of air pollution on the health of children living in the city of Cubatão, Brazil. In: WHO-Commission of Health and Environment. Report of the panel on industry, pp. 102-107, Geneva: World Health Organization.
- [13] **KOHONEN, T.** (1982). Self-organized formation of topologically correct feature maps , Biological Cybernetics, Volume 43, Number 1, 59-69.
- [14] **KOHONEN, T.** Exploratory data Analysis by the Self-Organizing Map: Structures Of Welfare And Poverty In The World , Neural Networks in Financial Engineering, 2001.
- [15] **KWANG-SOO, C.; INOUE, S. & SHINOZAKI, R.** (1997). Air pollution, temperature, and regional differences in lung cancer mortality in Japan. Archives on Environmental Health, 52:160-168.
- [16] **KASKI, S.** (1997). Data exploration using self-organizing maps, Mathematics, Computing and Management in Engineering Series, Number 82.
- [17] **LANDSDOWN, R. & YULE, W.** (The) Lead Debate: The Environment, Toxicology and Child Health. London: Croom Helm, 1986.
- [18] **LICHTENFELS, A. J; BOHM, G. & SALDIVA, P. H. N.** (1993). Correlação entre Poluição Atmosférica e Mortalidade em Idosos na RMSP. Reunião Anual da Sociedade

de Biologia Experimental, VIII Congresso Brasileiro de Biofísica, resumos. Caxambu, FESBE, p.72.

- [19] **LIVINGSTONE, KEN.** 50 years on. The struggle for air quality in London since the great smog of December 1952. Published by Greater London Authority City Hall The Queen's Walk London SE1 2AA, 2002.
- [20] **MEDEIROS, A.; GOUVEIA, N.** (2005). Relação entre baixo peso ao nascer e a poluição do ar no Município de São Paulo; Rev. Saúde Pública, 39 (6): 975-972
- [21] **RIBEIRO, H. P.; NOGUEIRA, D. P.; BONGIOVANNI, C. A. T.; SOUZA, J. M. P.; KOGA, R. K.; NEFUSSI, N.; GUIMARÃES, F. A. & OLIVEIRA, W. E.** Estudo da Função Ventilatória em Escolares Vivendo em Áreas com Diferentes Níveis de Poluição do Ar. São Paulo: Faculdade de Saúde Pública, Universidade de São Paulo, 1976.
- [22] **RUMELHART, D. E.; MCCLELLAND, J. L.; PDP RESEARCH GROUP.** Parallel Distributed Processing: Explorations in the Microstructure of Cognition, Volume 2, Psychological and Biological Models, 1986.
- [23] **SALDIVA, P. H. N.** (1993). Urban levels of air pollution are associated with increases of mortality due to respiratory diseases. European Respiratory Journal, 6:345-358.