

# **Um estudo sobre a violência em grandes metrópoles utilizando um tratamento das variáveis via redes neurais**

## **Mapas Auto-Organizáveis**

**Isnard T. Martins**

Professor Dr. Universidade Estácio de Sá, Rio de Janeiro, Brasil  
isnardthomasmartins@gmail.com

**Edgard T. Martins**

Professor Dr. Universidade Federal de Pernambuco, Brasil  
edgardpiloto@gmail.com

### **Resumo**

Este ensaio oferece uma classificação da violência nas capitais brasileiras, tratando índices de homicídios relacionados com a população, agrupando os resultados processados por meio de redes neurais. Os dados-fonte compreendem indicadores de homicídios por 100.000 mil habitantes, referentes às capitais brasileiras, editados pelo Ministério da Saúde (ano 2000) e os índices demográficos divulgados pelo IBGE (ano 2003). A visão final do estudo será o resultado do tratamento das variáveis processadas via rede neural, utilizando uma arquitetura SOM (*Self Organized Method*) Aprendizado Competitivo, agrupando as capitais em quatro *clusters*. Foi desenvolvido um método para extração de amostras organizacionais plotadas em espaço trigonométrico, complementado por algoritmo de classificação de estruturas que utilizam modelos de redes neurais com aprendizado não supervisionado SOM.

**Palavras-chave:** Redes Neurais, Aprendizado Competitivo, Pesquisa Operacional

### **Abstract**

This paper provides a classification of violence in Brazilian cities, treating homicide rates related to population, grouping processed using neural networks results. The source data include indicators of homicides per 100,000 inhabitants, referring to the Brazilian capitals, edited by the Ministry of Health (2003) and demographic indexes disclosed by the IBGE (2010). The ultimate vision of the study will be the result of treatment of the variables processed via neural network, using SOM (Self Organized Method) Competitive Learning architecture, gathering the capitals in four clusters. An original method to extract organizational samples plotted on trigonometric space was used.

**Keywords:** Neural Networks, Competitive learning, Operations Research

## 1. INTRODUÇÃO

Conhecido como mapas auto-organizáveis, é um método para classificação de subgrupos que analisa configurações organizacionais de informações, usando técnicas de classificação não supervisionada de dados, através de uma ferramenta que utiliza princípios aplicados de redes neurais. Esse método é utilizado para classificação de informações de entrada, não organizadas, desconhecendo-se possíveis classes ou padrões organizacionais referentes aos dados selecionados. Denominado SOM - Self Organized Maps aplica algoritmos de autoaprendizagem não supervisionada, cujos neurônios competem pela descoberta de padrões de entrada em um método conhecido como Aprendizado Competitivo, uma forma de aprendizado que particiona o conjunto de padrões de entrada em grupos específicos de dados em uma forma simplificada: *Winner takes all* (o ganhador leva tudo).

O objetivo deste algoritmo para aprendizagem auto-organizada é descobrir padrões significativos ou características nos dados de entrada, fazendo esta descoberta sem um professor. Para desenvolver a aprendizagem, o algoritmo dispõe de um conjunto de regras de natureza local, que o capacita aprender a calcular um mapeamento de entrada-saída com propriedades desejáveis específicas. O termo local significa que a aplicação ao peso sináptico de um neurônio está limitada à vizinhança imediata daquele neurônio. O processo de aprendizagem consiste em modificar repetidamente os pesos sinápticos das conexões de uma rede neural em resposta a padrões de ativação, atendendo às regras pré-estabelecidas, até se desenvolver uma configuração final para a amostra selecionada.

## 2. O MÉTODO

Um método utilizado em redes neurais, conhecido como mapas auto-organizáveis, é utilizado para classificação de informações de entrada, onde se encontram classes desconhecidas ou padrões organizacionais inerentes aos dados selecionados. Um destes métodos é denominado SOM - *Self Organized Maps*, que aplica algoritmos de autoaprendizagem (não supervisionada), cujos neurônios competem pela descoberta de padrões de entrada em um método conhecido como *Competitive Learning*, uma forma de aprendizado que particiona o conjunto de padrões de entrada em grupos específicos de dados (VELASCO, 2005). Usando um *software* para tratamento de variáveis normalizadas *Visual Som*, desenvolvido pelo autor (MARTINS, 2013), os dados coletados de bases de informações criminais foram processados para a análise SOM. Para efeitos de ensaio, foram coletados dados das principais cidades brasileiras no ano 2000, que depois de normalizados, transformam-se em vetores tratados que podem assumir intervalos de valores máximos e mínimos, que podem variar de +1 a -1. As interações sucessivas treinam a rede neural, construindo os números de *Clusters* desejados pelo ensaio. Os resultados deste ensaio foram agrupados em quatro *Clusters*, representativos dos dados quanto à relação de crimes por 100.000 habitantes nas cidades analisadas.

## 3. APRENDIZAGEM COMPETITIVA

As Redes Neurais têm sido extensivamente usadas para finalidades múltiplas onde são exigidos princípios matemáticos para descoberta de padrões de entrada em grupos inerentes de dados. Aplicações diversas utilizando redes neurais são relatadas na literatura. Hauck (2002) cita a aplicação de redes neurais para extração de entidades de textos pela polícia de Tucson, Texas. Xu e Chen (2004) citaram o uso de redes neurais para identificação de caminhos mínimos em grafos, aplicando uma rede Hopfield de duas camadas para pesquisa do problema de caminho mínimo e Hollmen *et al* (1999) citam aplicações para reconhecimento de padrões, análise de imagem, monitoramento e controle de processos, e diagnóstico de falhas.

As Redes Neurais são capazes de generalizar o seu conhecimento a partir de exemplos anteriores, com habilidade de lidar com ruídos e distorções, respondendo corretamente a padrões novos (VELASCO, 2005). As redes Neurais encontram aplicações em campos diversos como modelagem de dados, análise preditiva em séries temporais, reconhecimento de padrões,

devido a uma importante característica: habilidade de aprendizado a partir de entrada de dados com ou sem supervisor.

Segundo Haykin (2001), o objetivo de um algoritmo para aprendizagem auto-organizada é descobrir padrões significativos ou características nos dados de entrada, fazendo esta descoberta sem um professor. Para desenvolver a aprendizagem, o algoritmo dispõe de um conjunto de regras de natureza local, que o capacita aprender a calcular um mapeamento de entrada-saída com propriedades desejáveis específicas. O termo local significa que a aplicação ao peso sináptico de um neurônio está limitada à vizinhança imediata daquele neurônio. O processo de aprendizagem consiste em modificar repetidamente os pesos sinápticos das conexões de uma rede neural em resposta a padrões de ativação, atendendo às regras pré-estabelecidas, até se desenvolver uma configuração final.

O principal objetivo de um mapa auto-organizável (SOM) é transformar um padrão de entrada de dimensão arbitrária em um mapa uni ou bidimensional, convertendo as entradas de forma adaptativa em um mapa topologicamente ordenado. São três os processos essenciais envolvidos na formação de um mapa auto-organizável:

- Competição - o neurônio com maior valor da função discriminante, que fornece a base para competição, é declarado vencedor.
- Cooperação - o neurônio vencedor determina a localização espacial de uma vizinhança topológica de neurônios excitados, fornecendo a base de cooperação para os neurônios vizinhos.
- Adaptação sináptica - permite que os neurônios excitados aumentem os seus valores individuais da função discriminante com relação ao padrão de entrada ajustando os seus pesos sinápticos.

### **3.1 CARACTERÍSTICAS DO APRENDIZADO COMPETITIVO**

Supondo que todos os vetores de entrada e vetores de peso estão normalizados, tem-se todos os vetores dentro de um círculo de raio 1.

Técnicas de classificação têm sido usadas para identificação de agrupamentos dotados de características homogêneas, também conhecidos por classes (KOHONEN,1995). Assumindo o desconhecimento de classes existentes ou relacionamentos entre as entidades de um grupo a priori, Kohonen (1995) cita o problema denominado de classificação não supervisionada, no qual são empregados métodos de agrupamento de dados para identificação de subgrupos.

Haykin (2008) cita que na Aprendizagem Competitiva, os neurônios de saída de uma Rede Neural competem entre si para se tornarem ativos, isto é, apenas um único neurônio de saída estará ativo em determinado instante. Esta característica é fundamental neste modelo de aprendizagem para permitir a classificação de um conjunto de padrões de entrada. Desta forma, o mecanismo de aprendizagem permite que apenas um único neurônio vencedor esteja ativo (“ligado”), o neurônio que “leva tudo”.

### **3.2 APLICAÇÃO DA FERRAMENTA VISUAL-SOM**

Foi desenvolvido pelo autor (MARTINS, 2009) um método para extração de modelos organizacionais do mapa de inteligência implementado em *Visual Basic 6*, capacitado por um algoritmo de classificação de estruturas organizacionais que utilizam modelos de redes neurais com aprendizado não supervisionado: O Sistema *Visual Som*, aplicativo para classificação não supervisionada de variáveis que fornece como resultado um mapa auto organizado SOM, tendo funções principais:

- Demonstrar graficamente os resultados promovidos por uma competição entre os processadores de uma rede neural auto-organizável.

- Apresentar e monitorar em tempo real a competição dos neurônios, exibindo em forma gráfica os movimentos das posições assumidas pelas interações durante a competição.
- Desenvolver ensaios para um método denominado Aprendizado Competitivo, fornecendo como resultado *Clusters* e agrupamento de dados padronizados.

O estudo de configurações características dos subgrupos extraídos de bases de informações podem revelar importantes resultados para identificação de padrões e grupamentos, através de sistema de aprendizagem não supervisionada.

Diferentes formatos de conectividade surgem nas configurações dos subgrupos, podendo ser classificados em classes com intuito de se estudar as semelhanças operacionais porventura existentes. Um ensaio utilizando este modelo foi aplicado para geração de *Clusters*, tomando-se uma base de informações de ocorrências criminais em capitais brasileiras.


A tabela 1 apresenta parcialmente os dados utilizados para tratamento pelo modelo de agrupamento de padrões. A tabela apresenta os dados originais recebidos e dados normalizados destinados à competição neural.

Capital	Homicídios por 100 mil	População	Dados de Homicídios Normalizados	Dados de População Normalizados
Aracaju	33,6	498.619	-0,003	-0,63
Belém	21,9	1.405.871	-0,350	0,05
Belo Horizonte	28,2	2.375.329	-0,163	0,78
Boa Vista	46,4	242.179	0,377	-0,82
Brasília	33,5	2.333.108	-0,006	0,75
Campo Grande	37,2	749.768	0,104	-0,44
Cuiabá	65,6	533.800	0,947	-0,60
Curitiba	21,1	1.757.904	-0,374	0,32
Florianópolis	11,1	396.778	-0,671	-0,70
Fortaleza	24,3	2.374.944	-0,279	0,78
Goiânia	22,2	1.201.006	-0,341	-0,10
João Pessoa	31,9	660.798	-0,053	-0,51
Macapá	43,4	355.408	0,288	-0,73
Maceió	37,9	903.463	0,125	-0,32
Manaus	32,4	1.644.690	-0,039	0,23
Natal	6,7	778.040	-0,801	-0,42
Palmas	21,8	208.165	-0,353	-0,84
Porto Alegre	30	1.428.696	-0,110	0,07
Porto Velho	60,7	373.917	0,801	-0,72
Recife	67,4	1.501.008	1,000	0,12
Rio Branco	35,2	305.731	0,045	-0,77
Salvador	11,8	2.673.560	-0,650	1,00
São Luís	14,9	978.824	-0,558	-0,27
Teresina	20,3	788.773	-0,398	-0,41
Vitória	54,4	313.312	0,614	-0,77

Tabela 1 – Lista parcial dos dados utilizados no ensaio para organização de Clusters

A função é gerada a partir de centroides ou classes que agruparão as entradas, resultando na segmentação das entradas em estruturas organizacionais semelhantes.

No exemplo ilustrado na figura 1, apresentam-se parcialmente vetores de entrada, distribuídos para uma competição pela busca por padrões de configurações organizacionais. O raio denominado de W4 (neurônio) representa um peso sináptico que competirá com outros pesos existentes pela busca de padrões pré-existentes de entrada.



- Identificação de potenciais similaridades organizacionais.
- Extração de configurações organizacionais selecionadas.
- Exportação da estrutura contendo a lista de configurações organizacionais para um ambiente de auto-aprendizado onde são aplicados princípios de redes neurais para classificação de padrões.
- Normalização dos dados para tratamento pelo algoritmo SOM.
- São atribuídas classes, segundo as quais se deseja agrupar as entradas (*Clusters*).

- Ativação de função *net* de auto-organização (competição), resultando em agrupamentos representativos das classes concentradoras das entradas em estruturas organizacionais semelhantes.

#### 4. ALGORITMO PROCESSADO PELO SISTEMA VISUALSOM (MARTINS, 2003)

Seja a matriz **M** representando um grafo, cujos elementos guardam valores pré-calculados correspondentes aos mais fortes vínculos entre cada par de entidades onde o acesso foi possível.

Seja **Li** uma lista de entradas (*Inputs*) contendo normalizados referentes às configurações (**i<sub>1</sub>, i<sub>2</sub>, i<sub>3</sub>...i<sub>n</sub>**) de indicadores população e delitos extraídos da matriz **M**.

As entradas correspondem a agrupamentos organizados sobre os quais se deseja obter padrões e semelhanças em suas configurações.

Seja **Lw** uma lista **Pesos** contendo processadores selecionados para identificação de *clusters*.

(**w<sub>1</sub>, w<sub>2</sub>, w<sub>3</sub>...w<sub>n</sub>**)

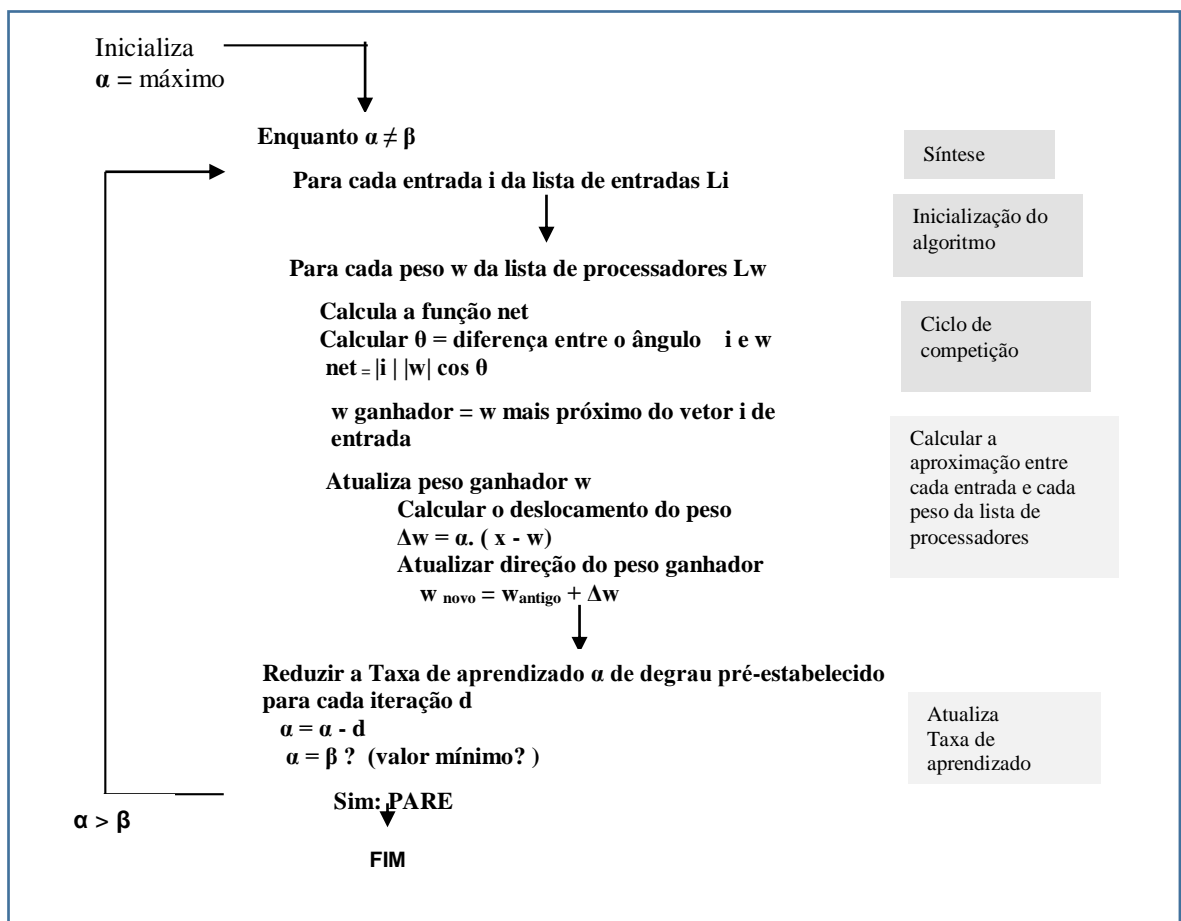
**α** contém uma taxa de aprendizado para evolução do algoritmo.

A taxa de aprendizado é inicializada com o valor máximo para **α** previsto para evolução do algoritmo.

**d** contém o valor do degrau pré-estabelecido para redução de **α**, a cada iteração do algoritmo.

Seja **β** o valor mínimo de **α** para finalização do ciclo de aprendizado.

Algoritmo *VisualSom* para classificação não supervisionada



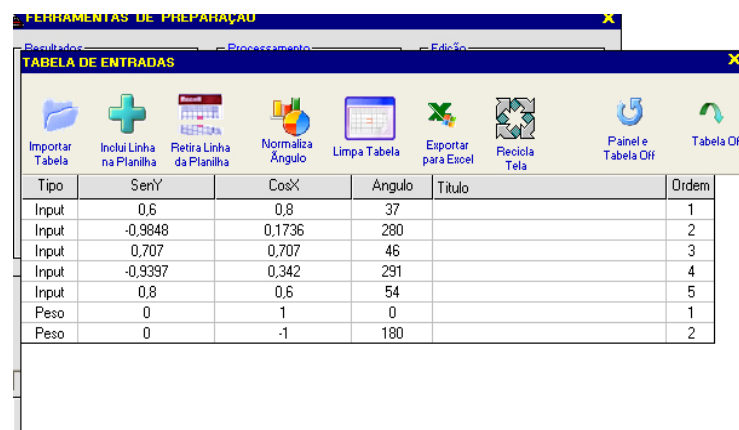
A competição ajusta os pesos de forma que os vetores de entrada similares ativem o mesmo neurônio. Somente o peso do neurônio vencedor é atualizado porque será o que melhor representa o padrão de entrada do grupo ao qual pertence.

A atualização dos pesos do processador vencedor aproxima ainda mais o vetor **W** do vetor de entrada corrente. A competição utiliza uma taxa de aprendizado ( $\alpha$ ), normalmente assumindo valor adaptativo entre 0.5 e 0.1, que decresce mono tonicamente com o aprendizado.

Kohonen (1995) cita que os dados devem ser normalizados antes da aplicação do algoritmo de auto-organização. Este procedimento não é obrigatório, porém recomendável, face ao provimento de melhor precisão numérica e tratamento dos limites dos dados de entrada.

## 5. INFORMAÇÕES COMPLEMENTARES SOBRE A COMPETIÇÃO E COMANDO DO ENSAIO

A figura 2 ilustra o painel gráfico do sistema *VisualSom* onde são distribuídas as entradas para classificação.



Tipo	SenY	CosX	Angulo	Titulo	Ordem
Input	0,6	0,8	37		1
Input	-0,9848	0,1736	280		2
Input	0,707	0,707	46		3
Input	-0,9397	0,342	291		4
Input	0,8	0,6	54		5
Peso	0	1	0		1
Peso	0	-1	180		2

Figura 2 – Tabela de Entrada das informações (MARTINS, 2009)

Uma das principais características do sistema *VisualSom* é apresentar dinamicamente a evolução da competição, permitindo acompanhar a trilha de deslocamento de cada neurônio durante a competição. As entradas, opcionalmente, podem ser apresentadas no painel gráfico rotuladas com códigos mnemônicos ou com títulos originais de entrada (nomes originais das entradas). Linhas coloridas diferenciadas apresentam o curso de ação de cada neurônio durante a competição. Cada fase da competição utiliza uma taxa de aprendizado que é utilizada pelo algoritmo SOM, que decai mono tonicamente em sucessivas iterações, até um limite pré-estabelecido, finalizando o ciclo de aprendizado. Os comandos para operação são ativadas a partir do Painel de Comando do *VisualSom* (figura 3).

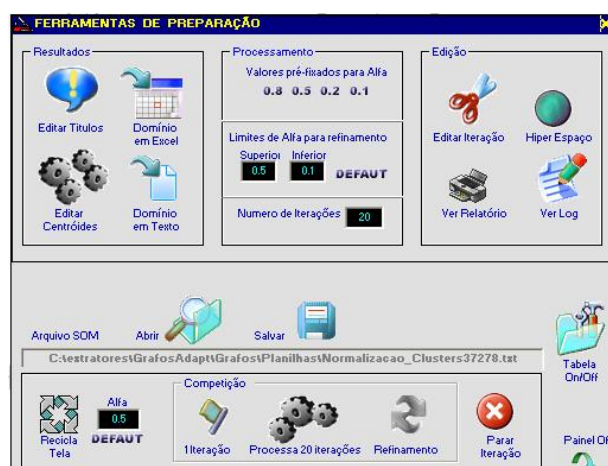


Figura3 – Painel de Funções e Controle Visual Som (MARTINS, 2009)

A competição dos processadores tem início pressionando-se [F11] ou diretamente no Painel. Com esta operação o sistema realiza 20 ciclos completos, utilizando os parâmetros fixados no painel de Funções (Valor de Alfa e número de ciclos da competição).

A fase seguinte seria a operação de refinamento, decaindo à taxa de aprendizado (valor de Alfa) em sucessivas iterações. A figura 4 apresenta um Painel Monitor da Competição. A barra indica o progresso do processamento. O painel mais claro no alto apresenta a taxa de aprendizado corrente em uso e *leds* que indicam se a rede está aprendendo ou encontra-se paralisada no ciclo atual. O sinaleiro também indica o aprendizado, apresentando a fase verde, se ativada ou vermelha se paralisada. Se o usuário deseja interromper o processamento basta dar um clique do mouse sobre o sinal. Este pequeno *led* ao lado do comutador do painel é ativado por erros originados na operação do programa.

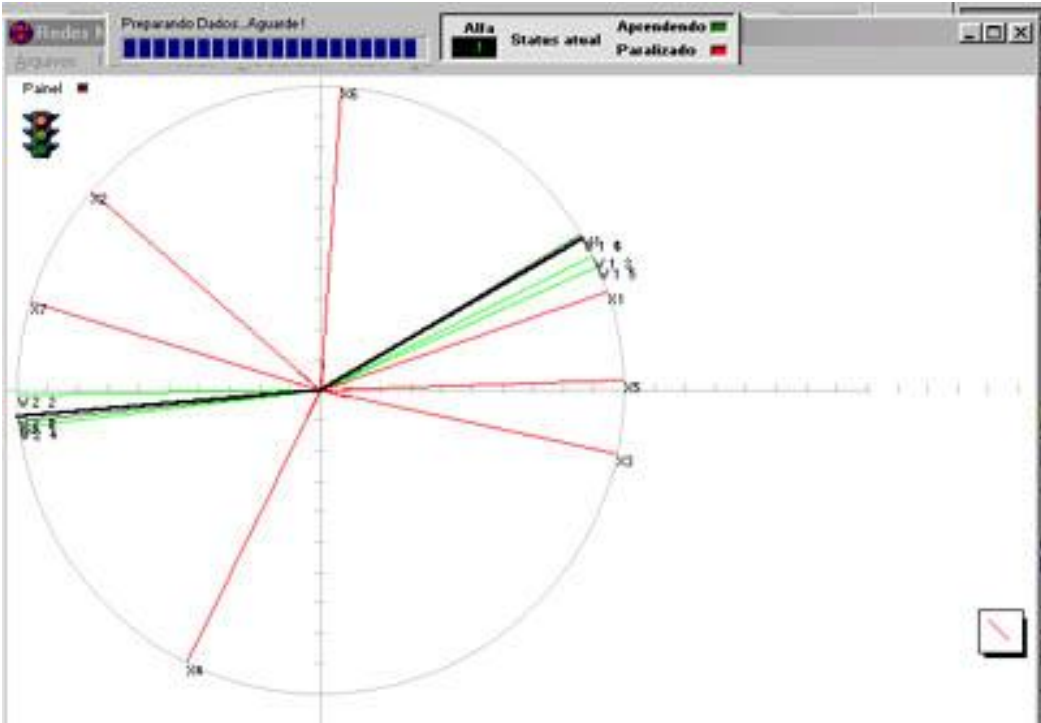


Figura 4- Painel monitor da competição de vetores (MARTINS, 2009)


## 6. MODELO DE APRENDIZADO COMPETITIVO

O sistema *VisualSom* utilizou princípios do aprendizado competitivo (KOHONEN, 2001), objetivando à busca de padrões organizacionais semelhantes nos dados de entrada. O processamento foi realizado a partir de um arquivo temporário exportado em *Excel*, contendo dados normalizados sobre os quais foi organizada uma pesquisa de padrões organizacionais. As principais características da função neural SOM utilizadas foram as seguintes:

Regra de propagação	$\text{net}_j = \sum x_j \cdot w_{ji} = \mathbf{x} \cdot \mathbf{w}_j$
Função de ativação	<b>Degrau (apenas para o neurônio vencedor)</b>
Topologia	<b>Uma única camada de processadores</b>
Algoritmo de aprendizado	<b>Não supervisionado</b> $\Delta w_{ki} = \alpha \cdot (\mathbf{x}_i - \mathbf{w}_{ki})$
Valores de entrada/saída	<b>Binários/contínuos</b>



**Aprendizado:**  $\Delta w_{ki} = \alpha \cdot (x_i - w_{ki})$



Somente o peso do neurônio vencedor é atualizado, porque será o que melhor representa aquele padrão de entrada do grupo ao qual pertence.

A atualização dos pesos do processador vencedor aproxima ainda mais o vetor **W** do vetor de entrada corrente. No caso de vetores normalizados, o processador vencedor é o que possui o vetor **W** mais próximo do vetor de entrada. O processador vencedor é o que possui maior valor de *net* (KOHONEN, 2001),

$$net_1 = \sum x_j \cdot w_{ji} = x \cdot w_j = \|x\| \|w_1\| \cos \theta = \cos \theta$$

A regra de propagação (soma ponderada) indica a proximidade dos dois vetores.

Usamos  $0 < \alpha < 1$  porque queremos o vetor **W** representando uma classe ou grupo de padrões e não um padrão específico. Desta forma **W** procura o centro do grupo.

O valor de  $\alpha$  deve ser adaptativo, decrescendo com o tempo.

## 7. CONCLUSÕES E RESULTADOS

A visão final do estudo foi o resultado do tratamento das variáveis processadas via rede neural, utilizando uma arquitetura SOM (*Self Organized Method*) Aprendizado Competitivo, agrupando as capitais em quatro *clusters* principais.

Após os primeiros resultados, foram observadas distorções causadas por vetores de grande magnitude contidos na amostra, como os representantes do Rio de Janeiro e São Paulo. Neste caso é recomendável desindexar tais valores e normalizar novamente os vetores, reprocessando o conjunto. Tais distorções causam uma concentração em um *cluster*, distribuindo de forma distorcida os demais nos *clusters* remanescentes superpovoados. A figura 4 ilustra uma classificação, na qual dois dos vetores (X22 e X25) apresentam valores excepcionalmente altos. Estes vetores extremos foram extraídos da amostra para pesquisa dos resultados finais reprocessados.

Nesta fase preliminar da análise, os vetores de entrada (valores numéricos) foram plotados no círculo trigonométrico, apresentando a distribuição ilustrada na figura 5.




Figura 5- Classificação apresentando distorção na distribuição de Vetores.

Podemos observar, no primeiro quadrante, as referências dos vetores Rio de Janeiro e São Paulo, que, devido à magnitude, causou uma distorção nos demais vetores do conjunto selecionado para o ensaio. A distorção concentrou a massa de dados restante no terceiro quadrante, por esta razão foram extraídos.

### 7.1 Resultados finais por quadrante

- o vetor relacionado com população, posicionada acima do eixo horizontal representará um valor relativamente alto;
- o vetor relacionado com a população, posicionada abaixo do eixo horizontal representará um valor relativamente baixo;
- o vetor relacionado com Índice de Homicídios, posicionada à direita do eixo vertical representará um indicador relativamente alto;
- o vetor relacionado com Índice de Homicídios, posicionada à esquerda do eixo vertical representará um indicador relativamente baixo;

Rio de Janeiro e São Paulo foram desindexados da classificação neural, sendo, entretanto, significativos para análise:

Capital	Índice por 100 mil habitantes	População
Rio de Janeiro	49,50	6.094.183
São Paulo	58,50	10.927.985

Os resultados reprocessados foram tratados e distribuídos em quatro quadrantes, distribuídos em quatro grupos, combinando-se os referenciais trigonométricos:

Magnitude	Índice populacional
$\text{Seno} > 0,5$	Grande
$0 < \text{Seno} < 0,5$	Médio/grande
$0 > \text{Seno} < -0,5$	Médio/pequeno
$\text{Seno} < -0,5$	Pequeno

Magnitude	Taxa de Homicídios
$\text{Coseno} > 0,5$	Grande
$0 < \text{Coseno} < 0,5$	Médio/grande
$0 > \text{Coseno} < -0,5$	Médio/pequeno
$\text{Coseno} < -0,5$	Pequeno

O hiperespaço ficou organizado, conforme ilustrado na figura 6 e a distribuição final dos vetores após a competição, conforme apresentado na figura 7.




Figura 6 – configuração de distribuição dos vetores




Figura 7 – Resultados processados pós-tratamento da competição não supervisionada

Usando como ambiente de classificação um círculo trigonométrico (hiperespaço), as variáveis foram distribuídas nos quadrantes do espaço onde, após processamento, foram gerados centroides (neurônios) melhor representativos das capitais em cada respectivo quadrante. As grandezas identificadas como "Grandes", "Pequenas", "Altas" ou "Baixas" são referências relativas, sem variações intermediárias ou subclassificações, restrições impostas somente para efeitos deste ensaio. Os resultados finais obtidos por este ensaio foram os seguintes (referências consideradas relativas e restritas):

<b>Quadrante 1</b> <b>Populacional - alto (+)</b> <b>Homicídios - alto (+)</b>	<b>Quadrante 2</b> <b>Populacional - alto (+)</b> <b>Homicídios - baixo (-)</b>	<b>Quadrante 3</b> <b>Populacional - baixo (-)</b> <b>Homicídios - baixo (-)</b>	<b>Quadrante 4</b> <b>Populacional - baixo (-)</b> <b>Homicídios - alto (+)</b>
<b>Recife</b>  <b>(Extraídos)</b> <b>Rio de Janeiro</b> <b>São Paulo</b>	<b>Belém</b> <b>Belo Horizonte</b> <b>Brasília</b> <b>Curitiba</b> <b>Fortaleza</b> <b>Manaus</b> <b>Porto Alegre</b> <b>Salvador</b>	<b>Florianópolis</b> <b>Goiânia</b> <b>Natal</b> <b>Palmas</b> <b>São Luís</b> <b>Teresina</b>	<b>Aracaju</b> <b>Boa Vista</b> <b>Campo Grande</b> <b>Cuiabá</b> <b>João Pessoa</b> <b>Macapá</b> <b>Maceió</b> <b>Porto Velho</b> <b>Rio Branco</b> <b>Vitória</b>
<b>Capital típica do</b> <b>Centroide 1</b>	<b>Capital típica do</b> <b>Centroide 2</b>	<b>Capital típica do</b> <b>Centroide 3</b>	<b>Capital típica do</b> <b>Centroide 4</b>
<b>Recife</b>	<b>Salvador</b>	<b>Teresina</b>	<b>Boa Vista</b>

Como resultado deste estudo, o ensaio ofereceu uma classificação da violência nas capitais brasileiras, tratando índices de homicídios relacionados com a população, agrupando os resultados processados por meio de redes neurais. Os dados-fonte compreenderam indicadores de homicídios por 100.000 mil habitantes, referentes às capitais brasileiras, editados pelo Ministério da Saúde (ano 2000) e os índices demográficos divulgados pelo IBGE (Instituto Brasileiro de Geografia e Estatística).

## 8. REFERÊNCIAS BIBLIOGRÁFICAS

- HAUCK, R.V. H.** *et al.* Using coplink to analyze criminal-justice data. *IEEE Computer* 35 (3), p. 30-37, 2002.
- HAYKIN, S.** *Neural networks: a comprehensive foundation.* Macmillan College Publishing Company: USA, 2008.
- \_\_\_\_\_. *Redes neurais, princípios e prática.* 2. ed. Porto Alegre: Bookman, 2001.
- HOLLMEN, J.** *et al.* Process modeling using the self-organizing map. *Integrated Computer-Aided Engineering Journal IOS Press*, 1999.
- KIANG, Melody.** Extending the Kohonen self-organizing map networks for clustering analysis. *Computational Statistics & Data Analysis*, 38, p. 161-180, 2001.
- KOHONEN, T.** The basic som: self-organizing maps. *Springer Berlin Heidelberg*, p. 105-176, 2001.
- \_\_\_\_\_. *Self-organization maps.* Berlin: Springer-Verlag, 1995.
- MARTINS, Isnard.** Software visual som - competitive learning: redes neurais. *DEI, PUC, Rio de Janeiro*, 2005/2006/2009.
- \_\_\_\_\_. *Descoberta de conhecimento em históricos criminais: algoritmos e sistemas.* 2003. Monografia (Tese de Doutorado – Engenharia Industrial) – PUC, Rio de Janeiro.
- VELASCO, Marley.** Redes neurais – notas. *ICA Núcleo de Pesquisa em Inteligência Computacional Aplicada, PUC, Rio de Janeiro*, 2005.
- VESANTO, J.; ALHONIEMI, E.** Clustering of the self-organizing map. *IEEE Trans. Neural Networks*, 11, p. 586-600, 2000.
- XU, Jennifer; CHEN, H.** Fighting organized crimes: using shortest-path algorithms to identify associations in criminal networks. *Decision Support System*, 38, p. 473-487, 2004.