



SPOLM 2007

ISSN 2175-6295

Rio de Janeiro- Brasil, 08 e 09 novembro de 2007.

## **AGRUPAMENTO DE TRAÇOS DE PERSONALIDADE USANDO REDES NEURAIAS ARTIFICIAIS**

### **Fábio Rodrigues Silva**

Universidade Federal do Rio de Janeiro, Cidade Universitária, Centro de Tecnologia, Programa de Engenharia de Produção, F103, Ilha do Fundão, 21945-970, Rio de Janeiro, RJ – Brasil, Caixa Postal 68548.  
rodrigues@pep.ufrj.br

### **Marcos Pereira Estellita Lins**

Universidade Federal do Rio de Janeiro, Cidade Universitária, Centro de Tecnologia, Programa de Engenharia de Produção, F103, Ilha do Fundão, 21945-970, Rio de Janeiro, RJ – Brasil, Caixa Postal 68548.  
estellita@pep.ufrj.br

### **Luiz Biondi Neto**

Universidade do Estado do Rio de Janeiro, Maracanã, Faculdade de Engenharia, Rua São Francisco Xavier, 524, sala 5019, bloco B, 20550-013, Rio de Janeiro, RJ – Brasil.  
luizbiondi@terra.com.br

#### **Resumo:**

Este trabalho é uma aplicação o uso de redes neurais artificiais, mais especificamente mapas auto-organizáveis de kohonen, para agrupar adjetivos de traço de personalidade. Além de mostrar a capacidade de processamento dos mapas auto-organizáveis de kohonen também, atenta para aos problemas envolvendo relacionamento humano o qual através do auto-conhecimento poderá ser uma método para uma vida mais harmoniosa. Bom para isso seria necessário ter grupos de adjetivos que objetivassem uma determina dimensão da personalidade é o que está demonstrado nesse trabalho.

**Palavras-chaves:** Redes Neurais Artificiais, Mapas Auto-organizáveis de Kohonen, traço de personalidade.

#### **Abstract:**

This work is an application of artificial neural networks specifically self-organizing maps to cluster adjectives of personality trait. Besides showing the capacity of processing of the of the kohonen maps also, it attempts for to the problems involving human relationship which can be a method for a more harmonious life through the self-knowledge. It would be necessary to have clusters of adjectives to aim at one determines dimension of the personality demonstrated in that work.

**Word-key:** Artificial Neural Networks, Kohonen Self-organizing, personality trait.

### **1. Introdução.**

O desenvolvimento de uma metodologia que vise definir as dimensões fundamentais da personalidade é muito mais do que uma necessidade é uma urgência. Em nosso ambiente de trabalho estamos sempre nos questionando no seguinte: “*quantos de nós já não estivemos*

envolvidos em situações onde o caráter da discussão passa ou até mesmo se inicia em contexto pessoal e não profissional”. Isso implica em reuniões demoradas, improdutivas, falta de consenso, desavenças, rixas; tanto na vida pessoal como na vida profissional do indivíduo, levando-nos a crer que as pessoas não se conhecem e não conhecem as outras.

O desenvolvimento da sociedade necessitará do desenvolvimento pessoal do indivíduo e da compreensão do outro, sem isso como a sociedade conseguirá refletir sobre seus próprios erros e suas contínuas transformações? Segundo Lins (2006) percebermos a manifestação das subpersonalidades, como elas se reproduzem e transmitem entre as pessoas, teremos possibilidade de promover uma transformação pessoal como fundamento para uma transformação social.

Segundo Pharterson apud Gurdjieff (1993) “(...) Se alguém imagina poder seguir o caminho do conhecimento de si, guiado por uma ciência exata de todos os detalhes, ou se espera adquirir tal ciência antes de se ter dado o trabalho de assimilar as diretrizes que recebeu, no que concerne a seu próprio trabalho, engana-se; deve compreender, antes de tudo, que nunca chegará à ciência (objetiva) antes de ter feito os esforços necessários e que somente seu trabalho sobre si mesmo permitirá atingir o que busca. Ninguém lhe poderá dar o que ele ainda não possui; nunca ninguém poderá fazer por ele o trabalho que ele deveria fazer por si mesmo. Tudo o que outro pode fazer por ele é estimulá-lo a trabalhar e, nesse ponto de vista, o símbolo compreendido como deve ser, desempenha o papel de um estimulante em relação à nossa ciência objetiva”.

Vários pesquisadores apontam para conceitos implícitos na tomada de decisão; conceitos estes que dependem o quanto nós conhecemos, segundo Ackoff (1979) para entender o conceito de otimilidade na pesquisa operacional falta levar em conta o valor intrínseco dos meios, traços e estilo a serem avaliados o que é seriamente difícil.

A busca do uso de uma metodologia para encontrar grupos de traços de personalidade os quais formariam as dimensões da personalidade torna possível uma melhor compreensão do nosso modo de ser, porém o nosso trabalho trata apenas do método quantitativo para agrupar esses traços de personalidade; fazendo apenas algumas implicações no que diz respeito a aplicação dos resultados e suas possíveis melhorias no campo relacional e conseqüentemente profissional.

## 2. Fundamentação Teórica

### 2.1. O mapa auto-organizável de Kohonen

A grande motivação das redes ou mapas auto-organizáveis SOM (self-organization maps) é baseada na característica do cérebro humano ser organizado por regiões de maneira que as entradas sensoriais sejam representadas por mapas topologicamente organizados. O mapa auto-organizável de Kohonen, (Fig. 1), emula esse aprendizado não supervisionado de forma simples e elegante, levando em consideração também, a vizinhança do neurônio Mitra (2002). Do exposto surge o princípio da formação de mapas topográficos, que visto sob o ponto de vista de Tuevo Kohonen, Kohonen (2001) é o seguinte: “A localização espacial de um neurônio de saída em um mapa topográfico corresponde a um domínio ou característica particular do dado retirado do espaço de entrada”.




Fig.1 - Rede auto-organizável de Kohonen

O objetivo é representar todos os pontos do espaço original por pontos num espaço menor, desde que a distância e relações de proximidade sejam preservadas quando for possível. Pereira & B. B., Rao, C. R., (2006).

Podemos, sinteticamente, dizer que existem três processos envolvidos na execução de um SOM: **Competição; Cooperação e Adaptação**. Analisando-se o **processo competitivo**, suponhamos que o espaço de entrada possua dimensão “m” e que **X** mostrado em (1) represente um padrão aleatório de entrada representado à partir desse espaço Haykin (1999). Assim:

$$\mathbf{X} = [x_1 \ x_2 \ x_3 \ \dots \ x_m]^t \quad (1)$$

Supondo-se que o vetor de pesos **W** de cada neurônio tenha a mesma dimensão do espaço de entrada, para um dado neurônio j de um total de l neurônios, o peso pode ser dado por (2):

$$\mathbf{W}_j = [w_{j1} \ w_{j2} \ w_{j3} \ \dots \ w_{jm}]^t, \quad j=1 \ 2 \ 3 \ \dots, l \quad (2)$$

Para cada vetor de entrada calcula-se o valor do produto interno, visando encontrar o vetor **X** que mais se aproxima do vetor de peso **W**. Matematicamente, essa operação equivale a minimizar a distância Euclidiana entre **X** e **W**. O neurônio que mais se aproxima do vetor de entrada **X**, representado em (3) é denominado de neurônio vencedor, cujo índice é **V(X)**.

$$V(\mathbf{X}) = \min \| \mathbf{X} - \mathbf{W}_j \|, \quad j=1 \ 2 \ 3 \ \dots, l \quad (3)$$

Através de um processo competitivo, um espaço contínuo de padrões de entrada pode ser mapeado em um espaço de saída discreto de neurônios.

No **processo cooperativo**, o neurônio vencedor define o lugar geométrico do centro da vizinhança topológica, definida biologicamente pela constatação de ligações interativas laterais entre um agrupamento de células neurais biológicas. Assim, aquele neurônio ativo (vencedor) tende a excitar, fortemente os neurônios vizinhos mais próximos dele e fracamente os mais distantes, ficando claro que a vizinhança topológica em relação ao neurônio que venceu a competição diminui com o aumento da distância lateral, Haykin (1999).

Dessa forma é preciso encontrar uma função de vizinhança topológica  $N_{j,V(\mathbf{X})}$ , independente da localização do neurônio vencedor representada em (4), que apresente vizinhança topológica com centro no neurônio vencedor indexado por V, tendo como vizinhos laterais mais próximos um grupo de neurônios excitados e cooperativos dos quais podemos escolher um representante denominando-o de neurônio j. Supondo que a distância lateral  $D_{j,V}$  entre o neurônio vencedor, indexado por V e o neurônio excitado indexado por j e que  $\sigma$  represente a largura da vizinhança, temos:

$$N_{j,V(\mathbf{X})} = \exp\left(-\frac{D_{j,V}^2}{2\sigma^2}\right) \quad (4)$$

A função de vizinhança topológica  $N_{j,V(\mathbf{X})}$ , deve obedecer as seguintes exigências Haykin (1999) e Mitra (2002): Ser simétrica em relação ao ponto no qual ocorre o máximo caracterizado pelo neurônio vencedor, indexado por  $V(\mathbf{X})$ , no qual  $D_{j,V} = 0$  e Quando  $D_{j,V}$  tende para  $\pm \infty$  a magnitude da função de vizinhança topológica decresce, nonotonicamente, tendendo para zero, mostrada na Fig 2.




Fig.2 - Função de Vizinhança Topológica

O **processo adaptativo** é a última fase da formação auto-organizada do mapa de Kohonen sendo responsável pelo ajuste dos pesos das conexões entre os neurônios.

Devido às mudanças nas conectividades que ocorrerem em uma única direção, a regra de Hebb não pode ser usado da mesma maneira que era feita no aprendizado supervisionado, sob pena de levamos os pesos à saturação. Nesse sentido, será feita uma pequena modificação na regra de Hebb, incluindo-se o termo  $g(y_j) \mathbf{W}_j$  denominado de “termo de esquecimento”, no qual o termo  $\mathbf{W}_j$  é o vetor peso do neurônio excitado  $\mathbf{j}$  e  $g(y_j)$  é uma função escalar positiva da resposta  $y_j$  do neurônio  $\mathbf{j}$ . A restrição imposta a função  $g(y_j)$  é que no desenvolvimento em série de Taylor o termo constante seja zero. Assim,  $g(y_j) = 0$  para  $y_j = 0$ . Dessa forma a variação do peso no neurônio excitado  $\mathbf{j}$  da grade pode ser expresso em (5), na qual  $\eta$  representa a taxa de aprendizado. Como pode ser visto pela inspeção da referida equação o primeiro termo após o sinal de igualdade refere-se ao termo Hebbiano e o segundo ao “termo de esquecimento”, Haykin (1999) e Kohonen (2001).

$$\Delta \mathbf{W}_j = \eta y_j \mathbf{X} - g(y_j) \mathbf{W}_j \quad (5)$$

Em (6), representa-se uma função linear para  $g(y_j)$  atender a restrição do modelo. Assim:

$$g(y_j) = \eta y_j \quad (6)$$

Fazendo-se  $y_j = N_{j,v(x)}$ , podemos reescrever (5) em (7).

$$\Delta \mathbf{W}_j = \eta N_{j,v(x)} (\mathbf{X} - \mathbf{W}_j) \quad (7)$$

De forma iterativa, isto é baseado no *tempo discreto* “n” podemos finalmente escrever em (8) a equação que atualiza os pesos, passo a passo no processo iterativo de auto-organização, que é aplicado em todos os neurônios que estejam dentro da vizinhança topográfica do neurônio vencedor Haykin (1999) e Kohonen (2001).

$$\mathbf{W}_j(n+1) = \mathbf{W}_j(n) + \eta(n) N_{j,v(x)}(n) (\mathbf{X} - \mathbf{W}_j(n)) \quad (8)$$

### 3. Modelagem e Resultados

Os dados de entrada foram produzidos através de um questionário, contendo 166 perguntas e que não será apresentado nesse artigo. E aplicado a 70 entrevistados de nível superior e médio com idade variando entre 18 a 61 anos, gerando uma matriz de 166 por 140, sendo 70 por auto-avaliação e 70 por avaliação de outro em relação ao entrevistado.

O questionário apresenta uma auto-avaliação e uma avaliação do outro, assim sempre um entrevistado se avalia e avalia o outro colega, da mesma forma o colega se auto-avalia e avalia o colega que o avaliou.

A topologia usada foi hexagonal, a taxa de aprendizado variou entre 0,01 e 0,1 e o raio de vizinhança foi igual a unidade. Neste artigo só apresentaremos o resultado da rede [4x4].

O conjunto de representado na tabela 1 apresenta o resultado de um dos 16 grupos encontrados pela rede de Kohonen, usando-se topologia hexagonal de dimensão [4x4], com taxa de aprendizado variando entre 0,01 e 0,1 e raio de vizinhança igual a unidade. Nesse caso, a base de dados utilizada levou em consideração a auto-avaliação e a avaliação do colega, isto é processando uma matriz de dimensão [166 x 140], Kohonen (1996).

Nômade
Sádico
Sarcástico
Temperamento Impulsivo
Difícil
Egocêntrico
Excessivamente punitivo
FantasiOSO
Inflexível (emocionalmente)

Tabela 1: Resultado de um Grupo

O grupo em questão apresenta variáveis (adjetivos de traço de personalidade) consistentes, pois todas elas demonstram de certa forma estar relacionadas formando uma dimensão da personalidade. Uma dimensão da personalidade é um grupo com características similares.

Vamos comparar esse resultado a outros dois resultados um escolhendo apenas a avaliação do individuo sobre ele mesmo e outro ele avaliando seu colega. Para isto foi

utilizado o mesmo algoritmo uma vez utilizando os valores que correspondiam a resposta do entrevistado se auto avaliando e outra o entrevistado avaliando o colega.

Auto-avaliação:

Malévolo	Cínico
Medo de lugares abertos públicos	Claustrofóbico
Neurótico	Alcoólico
Arrogante	Egocêntrico
Sádico	Egoísta
Sarcástico	Excessivamente punitivo
Traíçoeiro	Exibicionista
Vingativo	Habilidade Musical
Auto-engana	Hipocondríaco
Brigão	Imitativo
Caluniador	

Tabela 2: Resultado da avaliação do próprio individuo

Este grupo foi escolhido devido ao mesmo conter a maior quantidade das variáveis (adjetivos de traço de personalidade) do grupo anterior (tabela 1) e isso poderia então validar a coerência entre os traços contidos nesse grupo. Os traços que se repetiram nesse grupo foram Sádico, Sarcástico, Egocêntrico e Excessivamente punitivo. Essas variáveis mantiveram uma coerência com as demais. Exceto Habilidade musical que não está agregando valor.

1. Avaliando o colega:

Malévolo	Caluniador
Mal-humorado	Cínico
Medo de lugares abertos públicos	Claustrofóbico
Neurótico	Alcoólico
Presunçoso	Egocêntrico
Arrogante	Egoísta
Sádico	Excessivamente punitivo
Sarcástico	Exibicionista
Traíçoeiro	Fantasiioso
Vingativo	Habilidade Musical
Auto-engana	Hipocondríaco
Brigão	Imitativo

Tabela 3: Resultado avaliando o colega

Analisando esse grupo podemos verificar que o primeiro grupo não está totalmente contido, porém é o grupo que mais variáveis continha do primeiro. Esse grupo também é consistente, exceto por Habilidade Musical todas as outras variáveis demonstram de certa forma estar relacionadas.

Esses resultados demonstram a consistência da aplicação de redes neurais para agrupar adjetivos de traço de personalidade.

**4. Conclusões**

Estes resultados apresentados demonstram só o trabalho executado pelo algoritmo sem nenhum refinamento. Se necessário podemos verificar a correlação existente entre os adjetivos de traço de personalidade de um determinado grupo como mostra a tabela 4.

Traços	Difícil	Egocêntrico	Excessivamente punitivo	Fantasiioso	Inflexível (emocional)	Nômade	Sádico	Sarcástico	Temperamento Impulsivo
Difícil	1	0,13	0,26	0,17	0,24	-0,10	0,19	0,13	0,14
Egocêntrico		1	0,43	0,15	0,09	0,08	0,37	0,34	0,15
Excessivamente punitivo			1	0,28	0,26	0,07	0,40	0,33	0,20
Fantasiioso				1	0,12	0,09	0,20	0,41	0,40
Inflexível (emocional)					1	-0,01	0,05	0,04	0,24
Nômade						1	0,23	0,21	-0,03
Sádico							1	0,63	0,10
Sarcástico								1	0,28
Temperamento Impulsivo									1

Tabela 4: Correlação entre os adjetivos de traço de personalidade

Essa correlação existente entre os dados pode nos ajudar a encontrar adjetivos de traço de personalidade que estejam com uma correlação muito baixa (próximo de zero) dentro desse grupo, podendo assim ser analisada melhor. Na tabela 4 verificamos o adjetivo de traço de personalidade Nômade que é um exemplo de correlação muito baixa o que significa que poderá ser retirado desse grupo.

Comparando essa metodologia usando mapas auto-organizáveis de Kohonen com a metodologia de correlação fatorial usada para encontrar os Cinco Grandes Fatores de Personalidade (The Big Five Personality Factors) podemos apontar como melhoria a agilidade no processo, pois com esta metodologia apresentada os grupos já estão formados, necessitando apenas em alguns casos de uma verificação interna dentro do grupo caso os dados de origem forem de boa qualidade.

Uma outra facilidade apresentada usando mapas auto-organizáveis de Kohonen é a possibilidade do pesquisador, ajustar a quantidade de grupos baseando-se em sua interpretação de como estavam os grupos formados anteriormente pelo algoritmo podendo assim aumentar ou diminuir a dimensão da rede.

Como esses dados ainda estão em processo de refinamento, às próximas melhorias que iremos fazer serem a retiradas da base de dados de todas as Habilidades e Interesses que são adjetivos de traço de personalidade que não estão a nosso entender agregando valor ao grupo onde elas se encontram. Também serão retirados todos os adjetivos de traços de personalidade que contiverem mais de 50% de suas respostas igual a 3, pois as respostas com esse valor são mal compreendidas pelo algoritmo podendo assim esses adjetivos de traço de personalidade irem pertencer a num grupo não adequado.

Com essas modificações esperamos ter resultado ainda melhor.

## 5. Bibliografia.

- 1 - Ackoff, R. L, The Future of Operational Research is Past , *The Journal of the Operational Research Society*, Vol. 30, No. 2 (Feb., 1979), pp. 93-104
- 2 - <http://ipip.ori.org/ipip/> - ultimo acesso dia 30.08.2007 às 17:13
- 3 - Lins, M. P. E (2006), Apostila do Curso de Consciência, Personalidade e Decisão, Universidade Federal do Rio de Janeiro.
- 4 - Kohonen, T., *Self-Organizing Maps*, 2ª ed., Espoo-Finland, Ed. Springer-Verlag-2006.
- 5 - Pereira, B. B., Rao, C. R, *Data Mining Using Neural Networks: A Guide for Statisticians*, (2006).
- 6 - S. Haykin , *Neural networks: a comprehensive foundation*, 2nd ed., Prentice Hall, New Jersey, 1999.
- 7 - T. Kohonen, J. Hynninen, J. Kangas, J. Laaksonen SOM\_PAK: *The Self-Organizing Map Program Package*, Technical Report A31, Helsinki University of Technology, 1996, disponível em <http://www.cis.hut.fi/nnrc/nnrc-programs.html>.
- 8 - T. Kohonen, *Self-Organizing Maps*. 3rd ed. Springer-Verlag, Berlin, 2001.

9 - P. Mitra, C.A Murthy, S.K Pal, *Unsupervised Feature Selection Using Feature Similarity*, IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 24, no. 3, 2002.