

Redes de Kohonen ou Self-organizing Maps (SOM)

- Germano Vasconcelos
- Centro de Informática
- Universidade Federal de Pernambuco

- Desenvolvidos por Kohonen em 1982
- Baseada em aprendizagem não-supervisionada, diferente das RNA na época
- Forte inspiração neurofisiológica
- Baseado em Aprendizagem Competitiva

Tipos de Aprendizagem I (pelo grau de feedback)



- **Supervisionada:** um "professor" diz quanto a resposta dada pelo sistema se aproxima da resposta desejada. (e. g. nota de um aluno numa prova)
- **Por Reforço:** um "professor" diz apenas se a resposta dada pelo sistema está certa ou errada. (e. g. punição/recompensa no treinamento de animais)
- **Não-Supervisionada:** o sistema tenta se auto-organizar baseado nas similaridades entre os exemplos a ele apresentados. (e. g. desenvolvimento das células simples do córtex visual estriado)



Tipos de Aprendizagem II (pelo grau de feedback)



- **Supervisionada:**
 - Conjunto de treinamento $s = \{(x_1, f(x_1)), (x_2, f(x_2)), \dots, (x_n, f(x_n))\}$
 - Convergência rápida
 - **Por Reforço:**
 - Conjunto de treinamento $s = \{(x_1, \text{sgn}[f(x_1)]), (x_2, \text{sgn}[f(x_2)]), \dots, (x_n, \text{sgn}[f(x_n)])\}$
 - Convergência média
 - **Não-Supervisionada:**
 - Conjunto de treinamento $s = \{(x_1,), (x_2,), \dots, (x_n,)\}$
 - Convergência lenta
-



Características Gerais das Redes de Kohonen



- Inspiração biológica
- Aprendizagem não supervisionada (clustering)
 - a aprendizagem agrupa padrões de características comuns
 - a rede é capaz de identificar as características comuns ao longo do domínio dos padrões de entrada
- Memória associativa
- Mapa topográfico de características
 - Quantização vetorial (compressão de dados)
 - Relações de vizinhança preservadas (transformações conformes)
 - Representação de espaços N-Dimensionais em 2-D



Inspiração Biológica



- Codificação distribuída em camadas (redes planas)
- Funções de ativação (vizinhança)
- Mapas topográficos
 - visão (ice cube, fóvea etc.)
 - tato
 - audição
- Aprendizagem biologicamente plausível
 - processo WinnerTakes All (canto de acasalamento)
 - liberação de óxido nítrico pelos neurônios ativos
 - membro fantasma (reaprendizagem dos córtices somato-sensorial e motor)



Inspiração Neurofisiológica

- Observação de imagens
 - Ressonância magnética (MRI)
 - Tomografia Computadorizada (CT)
- Diferentes estímulos geram
 - Regiões de excitação
 - Organização topográfica





Figura: Regiões ativas durante aplicação de acupuntura no ponto LI-5


Fonte: Neuro-imaging of Acupuncture Project

Inspiração Neurofisiológica



Rede de Kohonen

Estado
/Saída



Entrada

- * Camada de saída plana: grade 2-D
- * Os estados dos neurônios são as próprias saídas
- * Camadas de entrada e saída totalmente conectadas
- * Feedback na camada de saída apenas numa vizinhança de cada neurônio (excitação / inibição lateral)

Aprendizagem Competitiva



- Neurônios de saída da RNA competem entre si para se tornar ativos
- Apenas um neurônio de saída fica ativo em um determinado instante
- Três elementos básicos:
 - | Neurônios com mesma estrutura, com pesos diferentes, produzindo respostas diferentes a uma entrada
 - | Um limite imposto sobre a força de cada neurônio
 - | Mecanismo de competição entre neurônios, de forma que apenas um neurônio é vencedor em um dado instante



- Em cada momento o neurônio vencedor:
 - aprende a se especializar em agrupamentos de padrões similares
 - tornam-se detectores de características para classes diferentes de padrões de entrada
- O número de unidades de entrada define a dimensionalidade dos dados

Rede de Kohonen

- Espaço vetorial de entrada com dimensão d
- Cada amostra é um padrão representado por um vetor $x = [x_1, x_2, \dots, x_d]$
- A arquitetura consiste de 2 camadas de neurônios
 - Camada de entrada composta por d neurônios
 - Camada de saída (ou de Kohonen) formada por N neurônios denotados por: $A = \{c_1, c_2, \dots, c_N\}$
 - O vetor peso do neurônio j é representado por:
 - $w = [\omega_{j1}, \omega_{j2}, \dots, \omega_{jd}] \quad j = 1, \dots, N$



Mapas Auto-Organizáveis (Arquitetura)



- O vetor peso sináptico de cada neurônio da grade tem a mesma dimensão que o espaço de entrada
 - O vetor peso do neurônio j é representado por:
 - $w = [\omega_{j1}, \omega_{j2}, \dots, \omega_{jd}] \quad j = 1, \dots, N$
 - este vetor indica as coordenadas de sua localização no espaço de entrada d dimensional

Grades

- No caso bidimensional, dois tipos de grade são empregados: hexagonal ou retangular
 - Na hexagonal, cada neurônio possui 6 vizinhos diretos
 - Na retangular, cada neurônio possui 4 vizinhos diretos




Aspectos do Treinamento



- Agrupamentos dos neurônios em vizinhanças que funcionam como detectores de características
- Mapa topográfico auto-organizado por processo cíclico de comparação dos padrões de entrada com pesos dos neurônios
- A partir de regiões aleatoriamente setadas, rede cria uma representação local e auto-organizada da informação
- Seleciona o neurônio de maior resposta ao padrão de entrada e aumenta a resposta desse neurônio e da sua vizinhança



Função de Ativação Chapéu de Mexicano




O óxido nítrico liberado pelas células ativas é uma das substâncias que fazem esse papel.

Funções Chapéu de Mexicano no Sistema Visual




Retina

Núcleo
Geniculado
Lateral




Córtex
Estriado



Inspiração Neurofisiológica


- Quando um neurônio é excitado, uma área ao redor entre 50 e 100 μm também sofre excitação
- Além disso, uma área sofre inibição para impedir a propagação do sinal a áreas não relacionadas

➤ A figura ilustra a interação lateral entre os neurônios






Auto-Organização Biológica (Detecção de Bordas)


Seletividade à Orientação no Córtex



Vizinhança Adaptável para Detecção de Bordas



Representação das Cores a Partir dos 3 Componentes



Algoritmo de Aprendizagem



- 1. Inicializa-se a rede:
 - pesos (aleatórios entre $[0,1]$), raio da vizinhança, taxa de aprendizagem e taxa de redução da vizinhança
- 2. Apresenta-se padrão de entrada
- 3. Calcula-se distância Euclideana do vetor de entrada a cada neurônio j de saída
- 4. Seleciona-se o neurônio n_{j^*} de menor distância d_{j^*}
- 5 Adapta-se os pesos do neurônio n_{j^*} e da sua vizinhança N_{j^*} , segundo a regra:
 - $w_{ij}(t+1) = w_{ij}(t) + \eta(t)[x_i(t) - w_{ij}(t)] \cdot \Lambda_{i,j^*}$
- 6. Retorna-se a 2 enquanto existirem padrões
- 7. Reduz-se vizinhança e taxa de aprendizagem (convergência)
- 8. Retorna-se a 2 até total de iterações



- Assume-se que a rede de influência lateral produz uma distribuição gaussiana centrada no neurônio vencedor
- Aplica-se como regra de aprendizagem:

$$\mathbf{w}_j(t+1) = \mathbf{w}_j(t) + \eta(t) \Lambda_{q_j}(t) [\mathbf{x} - \mathbf{w}_j(t)]$$

↑
Vetor peso
atualizado

↑
Vetor peso
anterior

↑
Taxa de
aprendizagem

↑
Vizinhança

↑
Adaptação

Equação aplicada a todos os neurônios da grade dentro da região de vizinhança h_{vj}

$$\mathbf{w}_j(t+1) = \mathbf{w}_j(t) + \eta(t) \Lambda_{vj}(t) [\mathbf{x} - \mathbf{w}_j(t)]$$

↑
Vetor peso
atualizado

↑
Vetor peso
anterior



↑
Taxa de
aprendizagem

↑
Vizinhança

↑
Adaptação

Exemplos de Vizinhos

- Tipo bolha (neurônios são atualizados igualmente)




- Normalmente taxa de aprendizagem e vizinhança diminuem no tempo
- Função de vizinhança Λ é normalmente uma gaussiana:

$$\Lambda_{i,i^*}(n) = \exp\left(\frac{-d_{i,i^*}^2}{2\sigma^2(n)}\right)$$

- Com uma variância que decresce com a iteração. Inicialmente cobre todo o mapa e reduz progressivamente a próximo de zero (somente o vencedor é atualizado)

- Conforme vizinhança é reduzida rede move-se de competição “muito soft” (quase todo neurônio é atualizado) para competição “hard” (somente vencedor atualizado)
- SOM cria um espaço de saída discreto onde relações topológicas dentro das vizinhanças do espaço de entrada são preservadas

Redução de vizinhança



- Seleção de parâmetros é crucial para preservação de topologia
- Experiência mostrou que há duas fases na aprendizagem SOM:
 - Fase de ordenação topológica dos pesos, ou seja, definição das vizinhanças
 - Fase de convergência com o ajuste fino da distribuição de entrada

Fase de Ordenação



- Com T iterações, função de vizinhança decresce em geral linearmente com um raio (d) definido por ($N_0=initial$):

$$d(t) = 1 + (N_0 - 1)(1 - \frac{t}{T})$$

- Normalmente a taxa de aprendizagem é alta (acima de 0.1) para permitir à rede se auto-organizar. Ela também é linearmente ajustada:

$$\eta(t) = \eta_T + (\eta_0 - \eta_T)(1 - \frac{t}{T})$$

— η_0 é taxa de aprendizagem inicial e η_T é taxa final



Também pode ser usada uma função exponencial decrescente para a taxa de aprendizagem:

$$\eta(t) = \eta_0 \exp\left(-\frac{t}{\tau_2}\right)$$

onde τ_2 é o número total de iterações


Fase de Convergência




- Fase mais demorada, se mantém taxa de aprendizagem pequena (0.01) e usa-se menor vizinhança (somente neurônio ou seus vizinhos mais próximos)
- Escolha do número de neurônios é experimental. Número de saídas afeta a precisão do mapeamento e tempo de treinamento
- Aumento do número de neurônios aumenta a resolução mas aumenta muito tempo de treinamento



Exemplo: treinamento de uma rede
para representar uma grade de
pontos




Formação do Mapa Topográfico Uniforme



- Organização de dados
 - Redução de dimensionalidade
 - Reconstrução de Superfícies
- Agrupamentos de dados
 - Segmentação de Imagens
 - Mineração de dados
 - Classificação de documentos
- Classificação de dados
 - Reconhecimento de Caracteres
 - Reconhecimento de Fala

- Reconstrução de superfícies

nuvem de
pontos



mapa 3D do
objeto
reconstruído



MARI, J.F. Reconstrução de superfícies 3D a partir de nuvens de pontos usando redes neurais auto-organizáveis. Projeto Mestrado. 2006

- Segmentação de Imagens



Imagem Original




Imagem Segmentada

Y. Jiang, et.al. SOM Based Image Segmentation. Lecture Notes in Artificial Intelligence 2639, 2003, pp.640-643

<http://citeseer.ist.psu.edu/jiang03som.html>

Máquina de Escrever Fonética de Kohonen




Máquina de Escrever Fonética

Mapa Fonotópico

a a a ah h æ æ ó ó e e e
o a a h r æ l ó y y j i
o o a h r r r g g y j i
o o m a r m n m n j i i
l o u h v vm n n h hj j j
l u v v p d d t r h hi j
. . u v tk k p p p r k s
. . v k pt t p t p h s s

Máquina de Escrever Fonética

Seqüência Fonética



Reconhecimento de Caracteres

I recognized:

A

clear reset

recognize learn



Number of cycles:

A B C
D E H

You wrote:

A


Cycles done: 1000



**Centro
de Informática**
U · F · P · E



Mapa Mundial da Pobreza (saúde, nutrição, educação, etc)



ANALYZING AUTHORS AND ARTICLES USING KEYWORD EXTRACTION, SELF-ORGANIZING MAP AND GRAPH ALGORITHMS

Tommi Vatanen, Mari-Sanna Paukkeri, Ilari T. Nieminen and Timo Honkela


Adaptive Informatics Research Centre, Helsinki University of Technology,
P.O.Box 5400, FIN-02015 TKK, FINLAND,
E-mail: first.last@tkk.fi

Mineração de Textos

ACO	Andrew Coward, Tom Gedeon: Physiological Representation of Concepts in the Brain (AKRR'05)
AHY	Aapo Hyvärinen, Patrik Hoyer, Jarmo Hurri, Michael Gutman: Statistical Models of Images and Early Vision (AKRR'05)
BCA	Basilio Calderone: Unsupervised Decomposition of Morphology a Distributed Representation of the Italian Verb System (AKRR'08)
EGR	Eric Grégoire: About the Limitations of Logic-Based Approaches to the Formalisation of Belief Fusion (AKRR'05)
DST1	Dimitrios Stamovlasis: A Catastrophe Theory Model For The Working-Memory Overload Hypothesis - Methodological Issues (AKRR'08)
DST2	David Stracuzzi: Scalable Knowledge Acquisition Through Memory Organization (AKRR'05)
HSU	Hanna Suominen, Tapio Pahikkala, Tapio Salakoski: Critical Points in Assessing Learning Performance via Cross-Validation (AKRR'08)
JFL	John Flanagan: Context Awareness in a Mobile Device: Ontologies versus Unsupervised/Supervised Learning (AKRR'05)
JLA	Jorma Laaksonen, Ville Viitaniemi, Markus Koskela: Emergence of Semantic Concepts in Visual Databases (AKRR'05)
JSE	Jan Sefranek: Knowledge Representation For Animal Reasoning (AKRR'08)
JVA	Jaakko Väyrynen, Timo Honkela: Comparison of Independent Component Analysis and Singular Value Decomposition in Word Context Analysis (AKRR'05)
LHA	Lars Kai Hansen, Peter Ahrendt, Jan Larsen: Towards Cognitive Component Analysis (AKRR'05)
KLA	Krista Lagus, Esa Alhoniemi, Jeremias Seppä, Antti Honkela, Paul Wagner: Independent Variable Group Analysis in Learning Compact Representations for Data (AKRR'05)
MAN	Mark Andrews, Gabriella Vigliocco, David Vinson: Integrating Attributional and Distributional Information in a Probabilistic Model of Meaning Representation (AKRR'05)
MCR	Mathias Creutz, Krista Lagus: Inducing the Morphological Lexicon of a Natural Language from Unannotated Text (AKRR'05)
MMA	Michael Malý: Cognitive Assembler (AKRR'08)
MPO1	Matti Pöllä, Tiina Lindh-Knuutila, Timo Honkela: Self-Refreshing SOM as a Semantic Memory Model (AKRR'05)
MPO2	Matti Pöllä: Change Detection Of Text Documents Using Negative First-Order Statistics (AKRR'08)
MTA	Martin Takac: Developing Episodic Semantics (AKRR'08)
NRU	Nicolas Ruh, Richard P. Cooper, Denis Mareschal: A Reinforcement Model of Sequential Routine Action

Aplicação em Mineração de Textos

Centro
de Informática



DE PERNAMBUCO

br

Uso de redes de Kohonen para identificação de perfis de jogadores no World of Warcraft

Lia C. R. Lopes *Pollyana N. Mustaro

Instituto de Pesquisas em Tecnologia e Inovação (IPTI), Brazil

*Universidade Presbiteriana Mackenzie, Programa de Pós-Graduação em Engenharia Elétrica, Brazil

Esta seleção resultou em um grupo de 591 jogadores de ambas as facções. Estes jogadores constituíram a matriz de entrada do treinamento, juntamente com as variáveis escolhidas. As variáveis selecionadas para o treinamento incluíram as nove classes existentes, o número de relacionamentos encontrados no jogo e a pontuação do jogador. A

Para concluir este experimento foi utilizada a ferramenta SOM Toolbox 2.0 [SOM Toolbox 2005] para o software MatLab [Vesanto et al. 2000]. A matriz de entrada apresenta linhas que representam cada jogador da amostra e as colunas representam as onze variáveis selecionadas (número de relações, pontuação e as nove classes). Cada classe representa uma variável




Figura 4: Mapas resultantes do treinamento da Rede de Kohonen

Clusters Formados dos Jogadores




Tabela 2: Análise geral dos agrupamentos encontrados

cluster	classe	pontuação	n. relações	rank	nível	número de jogadores
8	Druid	0 a 1248	0 a 48	1 a 9	10 a 70	79
5	Hunter	39 a 1284	0 a 22	1 a 9	15 a 70	52
14	Hunter	668 a 1242	23 a 54	0 a 7	70	16
4	Mage	0 a 475	0 a 6	1 a 8	2 a 70	9
13	Mage	537 a 1266	0 a 48	1 a 8	67 a 70	56
6	Paladin	0 a 1231	0 a 40	0 a 9	9 a 70	60
16	Paladin	885 a 1160	40 a 55	0 a 4	70	7
7	Priest	0 a 321	0 a 26	4 a 7	24 a 70	10
9	Priest	525 a 1276	0 a 47	1 a 8	63 a 70	52
1	Rogue	0 a 1272	0 a 18	1 a 9	18 a 70	51
17	Rogue	717 a 1265	23 a 53	1 a 8	70	19
2	Shaman	0 a 365	0 a 3	4 a 7	10 a 60	8
12	Shaman	523 a 1280	0 a 24	1 a 8	64 a 70	46
15	Shaman	918 a 1075	32 a 50	2 a 4	70	6
11	Warlock	103 a 1270	0 a 50	1 a 9	23 a 70	55
10	Warrior	648 a 1287	0 a 26	1 a 9	70	44
18	Warrior	960 a 1303	37 a 55	2 a 4	70	9
3	Warrior	88 a 502	0 a 7	2 a 7	25 a 70	12

Figura 6: Numeração dos agrupamentos encontrados

Mapa Tridimensional – Clusters World of Warcraft




Figura 5: Mapa de saída tridimensional

Outra Aplicação



- Seleção do Par Ideal: Casamento, Encontros.
Pattern match
 - Treinamento da Rede de Kohonen com características dos indivíduos, como idade, altura, educação, interesses, o que buscam nos parceiros, etc.
 - Teste usando uma busca por “par-perfeito”
 - Retorno da Rede pode ser um cluster de “melhores-pares”



Identificação de Padrões de Comportamento em Dados de Internação no SUS



- Dados de 2008 a 2014
- Estado: Pernambuco
- 41 mil registros mensais
- 95 variáveis iniciais (pré-processamento para tratamento de inconsistências-ruído-ausência)



Identificação de Padrões de Comportamento em Dados de Internação no SUS




Tabela 4.1: Valores de configuração da rede SOM.


Configuração	Valor
Topografia	Hexagonal
Tamanho do mapa	15 x 15
Qtd. de épocas total	10.000
Qtd. de épocas na ordenação	1.000
Vizinhança no início da ordenação	5
Taxa de aprendizagem no início da ordenação	0,9
Vizinhança no início da fase de ajustes	1
Taxa de aprendizagem no início da fase de ajustes	0,02



Identificação de Padrões de Comportamento em Dados de Internação no SUS



(a) U-Matrix



(b) 15 clusters

Figura 4.5: U-Matrix e segmentação do mapa treinado.

Identificação de Padrões de Comportamento em Dados de Internação no SUS

Tabela 4.2: Índices de Davies-Bouldin para diferentes partições do mapa.

Quantidade de <i>clusters</i>	Índice de Davies-Bouldin
2	4,61
3	4,68
4	4,80
5	4,40
6	4,02
7	4,12
8	4,21
9	3,86
10	3,72
11	3,70
12	3,77
13	3,74
14	3,71
15	3,78

Davies-Bouldin

$$S_i = \left(\frac{1}{T_i} \sum_{j=1}^{T_i} |X_j - A_i|^p \right)^{1/p}$$

Identificação de Padrões de Comportamento em Dados de Internação no SUS




Figura 5.1: Indicador taxa de mortalidade.

Identificação de Padrões de Comportamento em Dados de Internação no SUS




Figura 5.2: Indicador taxa de cesáreas.

Identificação de Padrões de Comportamento em Dados de Internação no SUS




Figura 5.5: Indicador valores totais.

Principais Resultados



- Identificação de padrões discrepantes em certos clusters
- Identificação de valores discrepantes em gastos de unidades de saúde quando usada como referência a tabela do SUS
- Não significa necessariamente irregularidades, a análise indica discrepâncias que possibilitam maior investigação



Outros Aspectos



- Orientação espacial dos vetores é priorizada na avaliação de similaridade: normalização é necessária
- No treinamento, sistema se auto-organiza para mapear topograficamente características. Depois, são associados rótulos a cada região
- Plausibilidade biológica a torna candidata na interpretação de fenômenos biológicos (e.g. distúrbios de aprendizagem, membro fantasma etc.)



Algumas Referências



- <http://www.ai-junkie.com/ann/som/som1.html>
- Sistema de busca baseado no SOM: <http://www.gnod.net/>
- <https://www.visualcinnamon.com/2013/07/self-organizing-maps-creating-hexagonal/>
- Applet SOM 3D: <http://fbim.fh-regensburg.de/~saj39122/jfroehl/diplom/e-sample-applet.html>

