
Sieci samoorganizujące się na zasadzie współzawodnictwa



JERZY STEFANOWSKI

Instytut Informatyki
Politechnika Poznańska

Plan

1. Wprowadzenie
2. Wykrywanie grup – sieci LVQ
3. Reguły uczenia się konkurencyjnego
4. Projekcja wielowymiarowa
5. Sieci SOM i ich algorytmy uczenia
6. WebSOM i inne zastosowania
7. Uwagi końcowe



Wprowadzenie


- Inny tryb uczenia się:
 - Bez nadzoru (brak informacji y o zadanym wyjściu; tylko opis przykładów \mathbf{x})
 - Sieć sama powinna wykrywać istotne zależności w danych wejściowych, badać podobieństwo wektorów \mathbf{x} , rozpoznawania cech istotnych czy regularności bez „nadzoru”
 - Typowe zastosowanie → grupowanie, kodowanie i kompresja, projekcja wielowymiarowa, wykrywanie cech istotnych.
 - Kluczowe jest badanie podobieństwa wektorów (wejścia, wagi),
 - Miara iloczynu skalarnego wektora wag i wektora wejściowego
- Zasady uczenia się konkurencyjnego (przez współzawodnictwo)
- Tylko zwycięskie neurony lub ich sąsiedzi są nauczani (modyfikacja wag)
- Na ogół prostsza topologia sieci

Typowe zastosowania

- **Grupowanie obserwacji:** Sieć w wyniku procesu uczenia dokonuje podziału przykładów uczących na klasy (grupy) przykładów podobnych do siebie i przyporządkowuje każdej klasie różne elementy wyjściowe sieci – **sieci LVQ**.
- **Tworzenie mapy cech:** Dane wejściowe transformowane są z wielowymiarowej przestrzeni przykładów w „małowymiarową” przestrzeń ich cech charakterystycznych. Elementy warstwy wyjściowej są geometrycznie uporządkowane. Wymaga się, aby podobne przykłady wejściowe generowały aktywność bliskich geometrycznie elementów wyjściowych - **Sieci SOM Kohonena**.
- **Analiza czynników głównych:** Sieć posiada wyjście wieloelementowe, a każdy z elementów odpowiada za jeden z tzw. czynników głównych, według których określane jest podobieństwo sygnałów wejściowych.

Podstawowa sieć Kohonena LVQ

- Celem jest grupowanie wektorów wejściowych \mathbf{x}
- Istota działania \rightarrow podobieństwo
- Podobne wektory powinny pobudzać te same neurony
- Prosta topologia



- gdzie $y_j = \mathbf{w}_j \mathbf{x} = \sum_i w_{ij} x_i$
- Reguła konkurencyjnego uczenia się

Wektory i miary podobieństwa


- Dany jest zbiór uczący $\{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n\}$
- Podobieństwo dwóch wektorów – odległość Euklidesowa

$$\|\mathbf{x}_i - \mathbf{x}_j\| = \sqrt{(\mathbf{x}_i - \mathbf{x}_j)^T \cdot (\mathbf{x}_i - \mathbf{x}_j)}$$

- Równoważna miara cosinusowa (kątowna)

$$\cos(\theta) = \frac{\mathbf{x}_i^T \cdot \mathbf{x}_j}{\|\mathbf{x}_i\| \cdot \|\mathbf{x}_j\|}$$

$$\cos \theta_j = \frac{\mathbf{a}_j^T \mathbf{q}}{\|\mathbf{a}_j\|_2 \|\mathbf{q}\|_2} = \frac{\sum_{i=1}^t a_{ij} q_i}{\sqrt{\sum_{i=1}^t a_{ij}^2} \sqrt{\sum_{i=1}^t q_i^2}}$$



Sieć Kohonena - LVQ

- Przetwarza się kolejne wektory \mathbf{x} poszukując p grup – odpowiadają im wybrane neurony
- Przed rozpoczęciem uczenia wektory wag są inicjowane losowo (małe liczby z przedziału $-0.5;0.5$)
- Wektory wag są normalizowane dla kolejnych p neuronów

$$\hat{\mathbf{w}}_i = \frac{\mathbf{w}_i}{\|\mathbf{w}_i\|}$$

- Stosuję się regułę „zwycięzca bierze wszystko” w celu identyfikację neuronu zwycięzcy.
- Wagi neuronu zwycięskiego podlegają modyfikacji

Reguła „zwycięzca bierze wszystko”

- Określenie zwycięzcy:

$$\| \mathbf{x} - \hat{\mathbf{w}}_m \| = \min_{i=1, \dots, p} \| \mathbf{x} - \hat{\mathbf{w}}_i \|$$

- Alternatywnie iloczyn skalarny

$$\hat{\mathbf{w}}_m^T \mathbf{x} = \max_{i=1, \dots, p} \hat{\mathbf{w}}_i^T \mathbf{x}$$

- Zwycięzcą jest jeden neuron m . Korekcja wag \mathbf{w}_m odbywa się wyłącznie dla neuronu zwycięzcy według reguły:

$$\Delta \mathbf{w}_m = \eta \cdot (\mathbf{x} - \mathbf{w}_m)$$

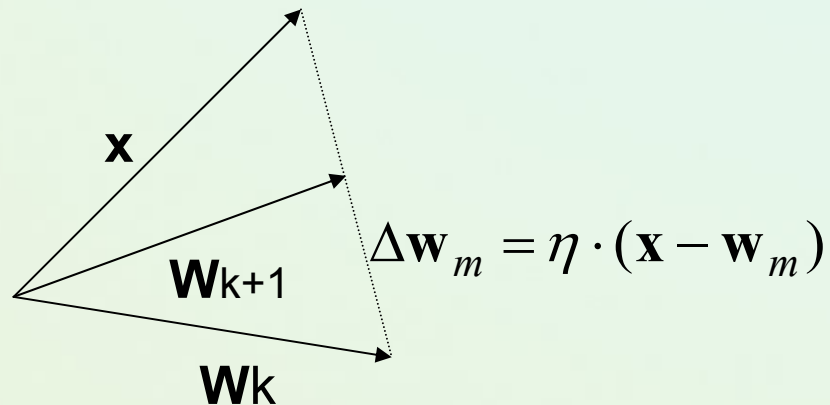
- η - stała uczenia (na ogół między 0.1 a 0.7)
- Przykład – interpretacja geometryczna

Uczenie zwycięskiego neuronu

- Po odnalezieniu zwycięskiego neuronu dokonuje się aktualizacji wag (k numer kolejnego kroku)

$$\mathbf{w}_m^{k+1} = \mathbf{w}_m^k + \eta \cdot (\mathbf{x} - \hat{\mathbf{w}}_m^k)$$

$$\hat{\mathbf{w}}_m^{k+1} = \frac{\mathbf{w}_m^{k+1}}{\|\mathbf{w}_m^{k+1}\|}$$



Kilka uwag o uczeniu sieci

- Po zakończeniu uczenia znormalizowane wektory wag (neuronów) wskazują środki ciężkości wykrytych grup obserwacji → analogia do k-średnich.
- Dobór wag początkowych – rozrzucenie po przestrzeni (hiperkuli)
- Problem doboru liczby neuronów (martwe neurony)
- Tzw. techniki sumienia → „sumienie” ten sam neuron nie zwycięża zbyt często
- Stopniowe zmniejszanie prędkości uczenia
- Iteracyjne powtarzanie prezentacji przykładów
- W ostatnim kroku – „kalibracja” sieci

Odzworowanie cech istotnych

- W eksploracji danych duże znaczenie ma transformacja wysoce-wielowymiarowych danych wejściowych w małowymiarowe przestrzenia tak aby zauważyć pewną harmonijną strukturę danych
- Podejścia analityczne (projekcje w statystyce)
np. PCA

Sieci SOM

- Podstawą odwzorowania takie uporządkowanie neuronów, takie że położenie zwycięskich neuronów niesie informacje
- Topologia \rightarrow relacja sąsiedztwa
- Podobne przykłady wejściowe x powinny aktywizować sąsiednie neurony
- „Gęstość” wzorców w zredukowanej przestrzeni musi odpowiadać gęstości przykładów w oryginalnej przestrzeni

Self-Organizing Feature Map (SOM)

- SOMs, also called topological ordered maps, or Kohonen Self-Organizing Feature Map (KSOMs)
- It maps all the points in a high-dimensional source space into a 2 to 3-d target space, s.t., the distance and proximity relationship (i.e., topology) are preserved as much as possible
- Similar to specific clustering: cluster centers tend to lie in a low-dimensional manifold in the feature space
- Clustering is performed by having several units competing for the current object
 - The unit whose weight vector is closest to the current object wins
 - The winner and its neighbors learn by having their weights adjusted
- SOMs are believed to resemble processing that can occur in the brain
- Useful for visualizing high-dimensional data in 2- or 3-D space

Unsupervised Learning:

Kohonen's Self-Organizing Map (SOM) [2]

- Another Clustering Algorithm

- aka Self-Organizing Feature Map (SOFM)


- Given: vectors of attribute values (x_1, x_2, \dots, x_n)

- Returns: vectors of attribute values $(x'_1, x'_2, \dots, x'_k)$

- Typically, $n \gg k$ (n is high, $k = 1, 2, \text{ or } 3$; hence “dimensionality reducing”)

- Output: vectors x' , the projections of input points x ; also get $P(x'_j | x_i)$

- Mapping from x to x' is topology preserving



- Topology Preserving Networks

- Intuitive idea: similar input vectors will map to similar clusters

- Recall: informal definition of cluster (isolated set of mutually similar entities)

- Restatement: “clusters of X (high-D) will still be clusters of X' (low-D)”

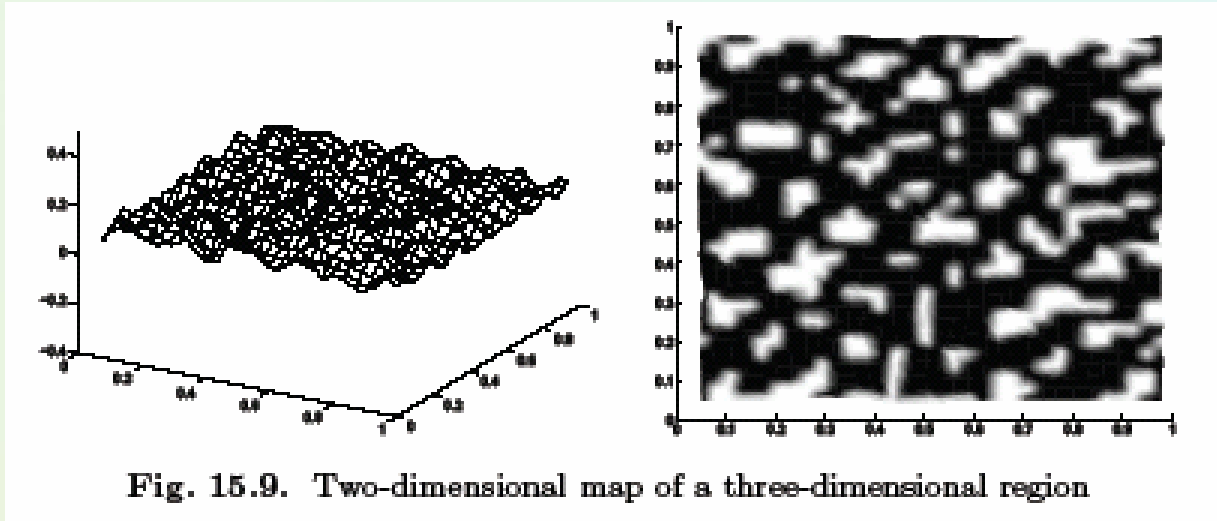
- Representation of Node Clusters

- Group of neighboring artificial neural network units (neighborhood of nodes)

- SOMs: combine ideas of topology-preserving networks, unsupervised learning

- Implementation: <http://www.cis.hut.fi/nncr/> and *MATLAB* NN Toolkit


Projekcja



Sieć 2D, dane 3D

o=dane

' = wagi sieci




przestrzeń cech

x y z


neurony wejściowe

wagi przypisane
połączeniom

2-D siatka
neuronów




Uczenie sieci 2D



Intuicja przekształcenia (A.Bartkowiak) z zachowaniem sąsiedztwa geometrycznego

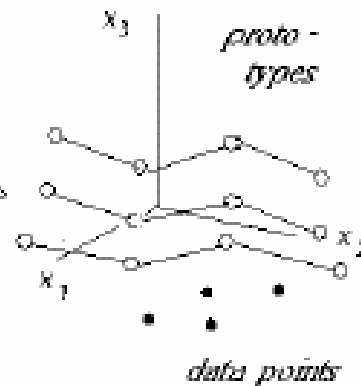
Kohonen



map

reference vectors

data space




Rysunek 7.1: Koncepcja mapy Kohonena. W trakcie 'uczenia' mapy punkty-prototypy są przyciągane do obszarów największej gęstości danych; jednak przy ograniczeniu, że musi być zachowane sąsiedztwo punktów referencyjnych na mapie {*kohtifl.eps*}

Mapa może być różnego kształtu i wymiaru. Mapa może być jednowymiarowa, dwuwymiarowa na płaszczyźnie lub torusie, trójwymiarowa itp. Najbardziej typową i najczęściej używaną jest mapa dwuwymiarowa o $M = m_1 \times m_2$ neuronach. Analizowane dane mają

Typowe topologie sieci SOM

- Dwie typowe topologie i sąsiedztwo



Rysunek 7.2: Sąsiedztwo na mapach Kohonena: Neurony ułożone w siatkę (strona lewa) hexagonalną i (strona prawa) prostokątną. {gridhr.JPG}

Uczenie SOM

Neurony reagują na sygnały \mathbf{X} podobne do \mathbf{W} .

Podobny = iloczyn skalarny największy lub odległość min.
Znajdź najsilniej reagujący neuron c .

$$\|\mathbf{X} - \mathbf{W}_j\| = \sqrt{\sum_i (X_i - W_{ij})^2}; \quad c = \arg \min_j \|\mathbf{X} - \mathbf{W}_j\|$$

Przesuń wagi neuronu c i neuronów w sąsiedztwie $O(c)$:


$$h(r, r_c, t) = h_0(t) \exp\left(-\|r - r_c\|^2 / \sigma_c^2(t)\right)$$

w stronę wektora \mathbf{X} :


$$\mathbf{W}_i(t+1) = \mathbf{W}_i(t) + h(r_i, r_c, t) [\mathbf{X}(t) - \mathbf{W}_i(t)] \quad \text{dla } i \in O(c)$$

Modelowanie sąsiedztwa

- Typowe funkcje



Rysunek 7.3: Jednowymiarowe funkcje sąsiedztwa dla promienia $R=2$: bubble, gaussian, cut-gaussian, Epanechnikov {figs7/neigh4.ps}.



Rysunek 7.4: Funkcje sąsiedztwa: bubble i gaussian określone na płaszczyźnie. Funkcja bubble wyznacza sąsiedztwo w sposób ostry: 1 - tak, 0 - nie; funkcja gaussian w sposób łagodny jako liczbę z przedziału $(0, 1)$. {bubble2.ps, gauss2.ps}

Algorytm SOM

Siatka neuronów $i = 1 \dots K$ w 1D-3D, każdy neuron z N wagami.

Neurony z wagami $\mathbf{W}_i(t) = \{W_{i1} \ W_{i2} \dots W_{iN}\}$, wektory $\mathbf{X} = \{X_1, X_2 \dots X_N\}$.

t - dyskretny czas; nie ma połączeń pomiędzy neuronami!

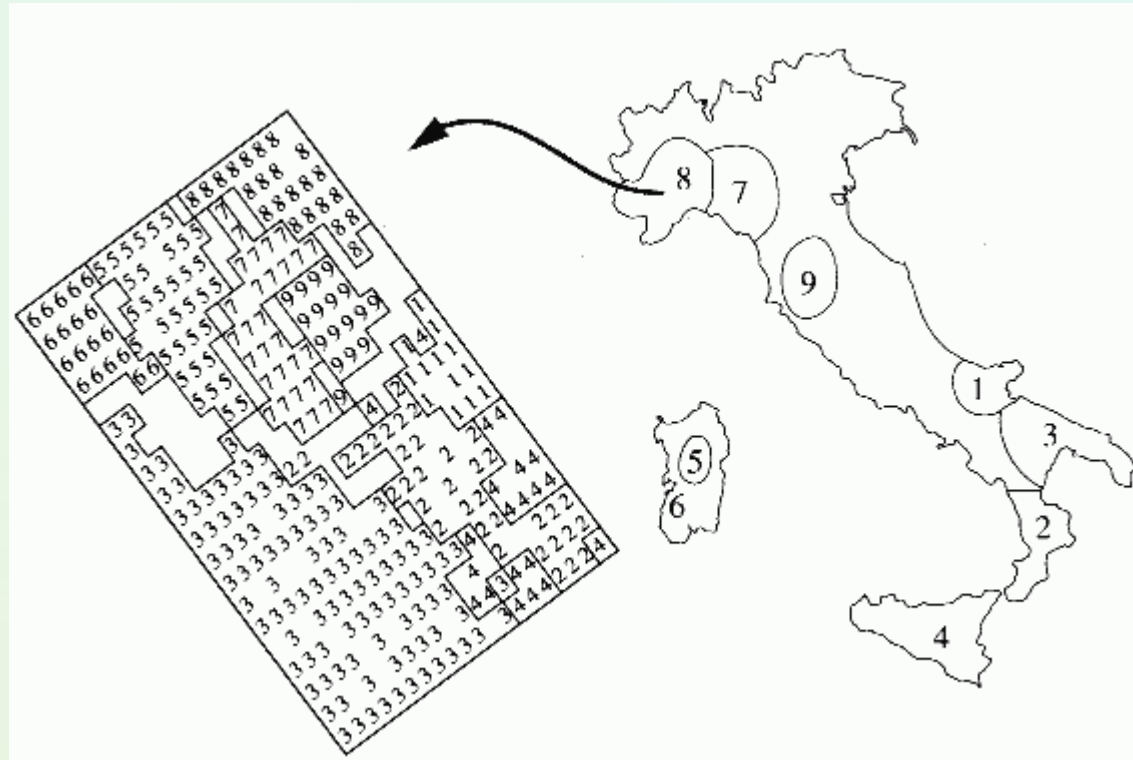
1. Inicjalizacja: przypadkowe $\mathbf{W}_i(0)$ dla wszystkich $i=1..K$.
Funkcja sąsiedztwa $h(|r-r_c|/\sigma(t), t)$ definiuje wokół neuronu położonego w miejscu r_c siatki obszar $O_s(r_c)$.
2. Oblicz odległości $d(\mathbf{X}, \mathbf{W})$, znajdź neuron z wagami W_c najbardziej podobnymi do X (neuron-zwycięzcę).
3. Zmień wagi wszystkich neuronów w sąsiedztwie $O_s(r_c)$
4. Powoli zmniejszaj siłę $h_o(t)$ i promień $\sigma(t)$.
5. Iteruj aż ustaną zmiany.

Efekt: podział (tesselacja) na wieloboki Voronoia.

An example of analysing olive oil in Italy

An example of SOM application:

- 572 samples of olive oil were collected from 9 Italian provinces. Content of 8 fats was determined for each oil.
- SOM 20 x 20 network,
- Maps 8D => 2D.
- Classification accuracy was around 95-97%.



Note that topographical relations are preserved, region 3 is most diverse.

Other examples

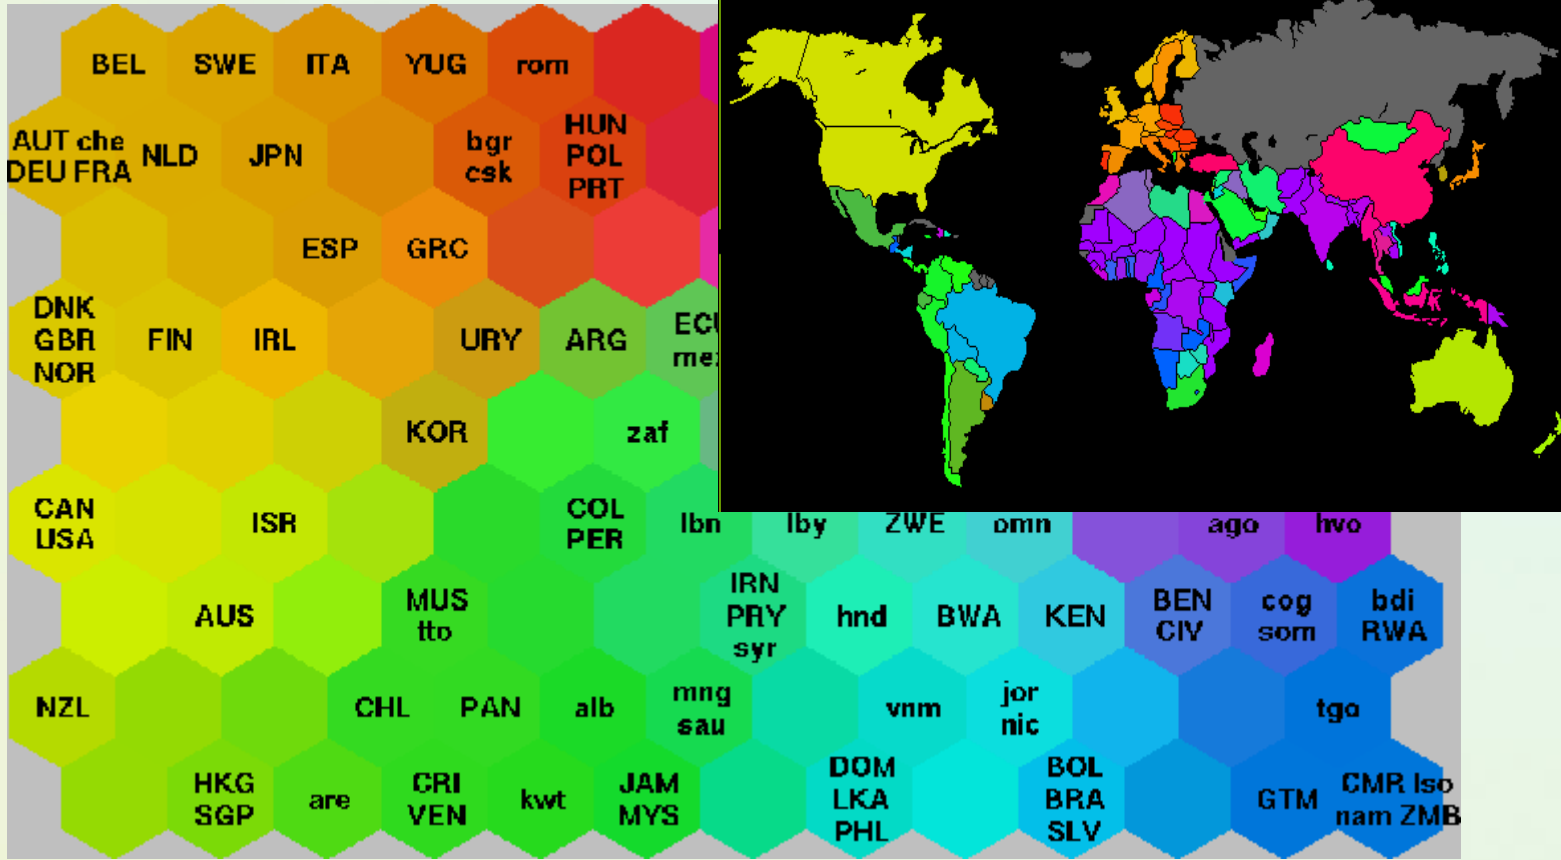
- Natural language processing: linguistic analysis, parsing, learning languages, hyphenation patterns.
- Optimization: configuration of telephone connections, VLSI design, time series prediction, scheduling algorithms.
- Signal processing: adaptive filters, real-time signal analysis, radar, sonar seismic, USG, EKG, EEG and other medical signals ...
- Image recognition and processing: segmentation, object recognition, texture recognition ...
- Content-based retrieval: examples of [WebSOM](#), Cartia, VisierPicSom – similarity based image retrieval.

Quality of life data

WorldBank data 1992, 39 quality of life indicators.


SOM map and the same colors on the world map.

More examples of business applications from <http://www.ubt.com/>



Analiza cech istotnych

- A self-organizing map showing [US Congress](#) voting patterns visualized in [Synapse](#). The first two boxes show clustering and distances while the remaining ones show the component planes. Red means a yes vote while blue means a no vote in the component planes (except the party component where red is [Republican](#) and blue is [Democrat](#)).





The Self-Organizing Map (SOM)

by Teuvo Kohonen

Introduction

The SOM is a new, effective software tool for the visualization of high-dimensional data. It converts complex, nonlinear statistical relationships between high-dimensional data items into simple geometric relationships on a low-dimensional display. As it thereby compresses information while preserving the most important topological and metric relationships of the primary data items on the display, it may also be thought to produce some kind of abstractions. These two aspects, visualization and abstraction, can be utilized in a number of ways in complex tasks such as process analysis, machine perception, control, and communication.

The SOM usually consists of a two-dimensional regular grid of nodes. A model of some observation is associated with each node (cf. Fig. 1).




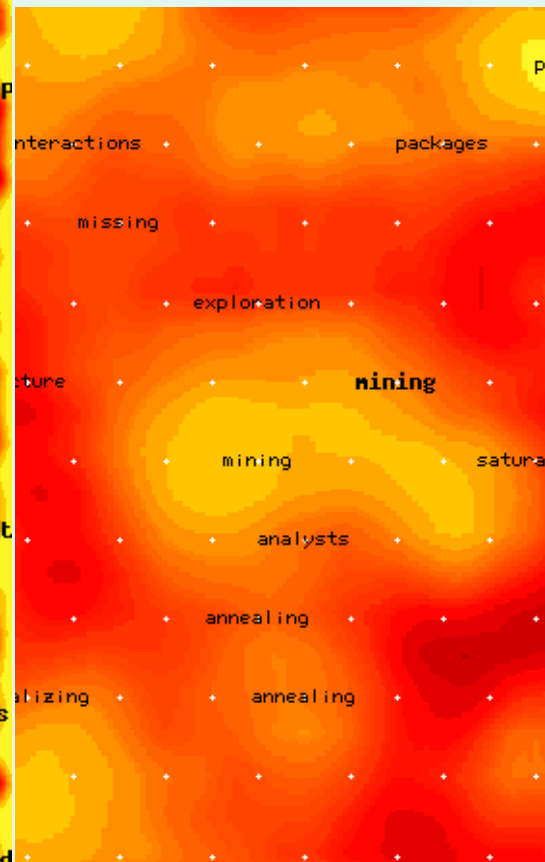

Figure 1: In this exemplary application, each processing element in the hexagonal grid holds a model of a short-time spectrum of natural speech

Web Document Clustering Using SOM

The result of SOM clustering of 12088 Web articles

The picture on the right: drilling down on the keyword “mining”

Based on websom.hut.fi Web page



Gaz neuronowy

Wariant uczenia konkurencyjnego (Schulten i Martinez 1991)

Algorytm NG typu SOM:


1. przypadkowa inicjalizacja N wektorów; $t=0$;
2. Wybierz przypadkowy wektor V
3. Zrób ranking wag najbliższych

$$\|W_i - V\| \leq \|W_j - V\|; i < j$$

Zastosuj regułę adaptacji:

$$\Delta W_i = \varepsilon(t) h_\lambda(i) (V - W_i)$$

zmniejszając eksponencjalnie





BEATCA – nowa koncepcja wyszukiwarki o interfejsie mapowym (M.Kłopotek, K.Ciesielski, D.Czerski, M.Dramiński – IPI PAN Warszawa)

- Nowa koncepcja wyszukiwarki mapowej
 - Pełen cykl przetwarzania miliona dokumentów - 48 godz.
 - współistnienie wielu koncepcji map (SOM, GNG, Immunologiczne)
 - współistnienie wielu koncepcji reprezentacji map (czwotokątne, sześciokątne, dwuwymiarowe euklidesowskie, hiperboliczne "rybie oko", prezentacja na kuli, torusie, walcu)
 - **Możliwość przyrostowego generowania mapy**
 - **Środowisko do badań eksperymentalnych nad nowymi koncepcjami map**

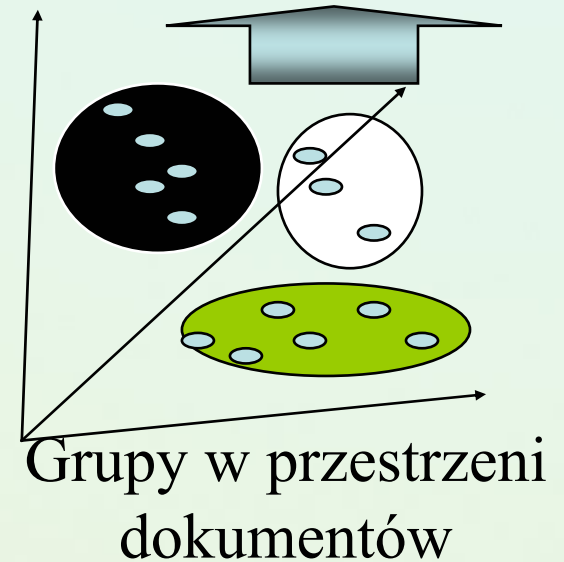
Etapy tworzenia mapy



Zbiór dokumentów



Mapa dokumentów



User interface of BEATCA software


Wyszukiwarka --Beatca-- - Microsoft Internet Explorer

Edycja Widok Ulubione Narzędzia Pomoc

Wstecz Wyszukaj Ulubione

http://localhost:8080/beatca/ Przejdź

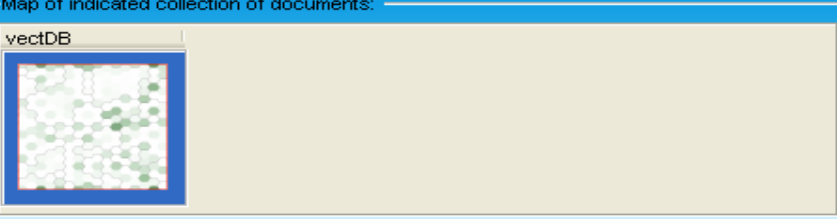
BEATCA Zoom: 1x Sphere 3D



Effect of sight Search

Collection of documents:

Map of indicated collection of documents:



vectDB

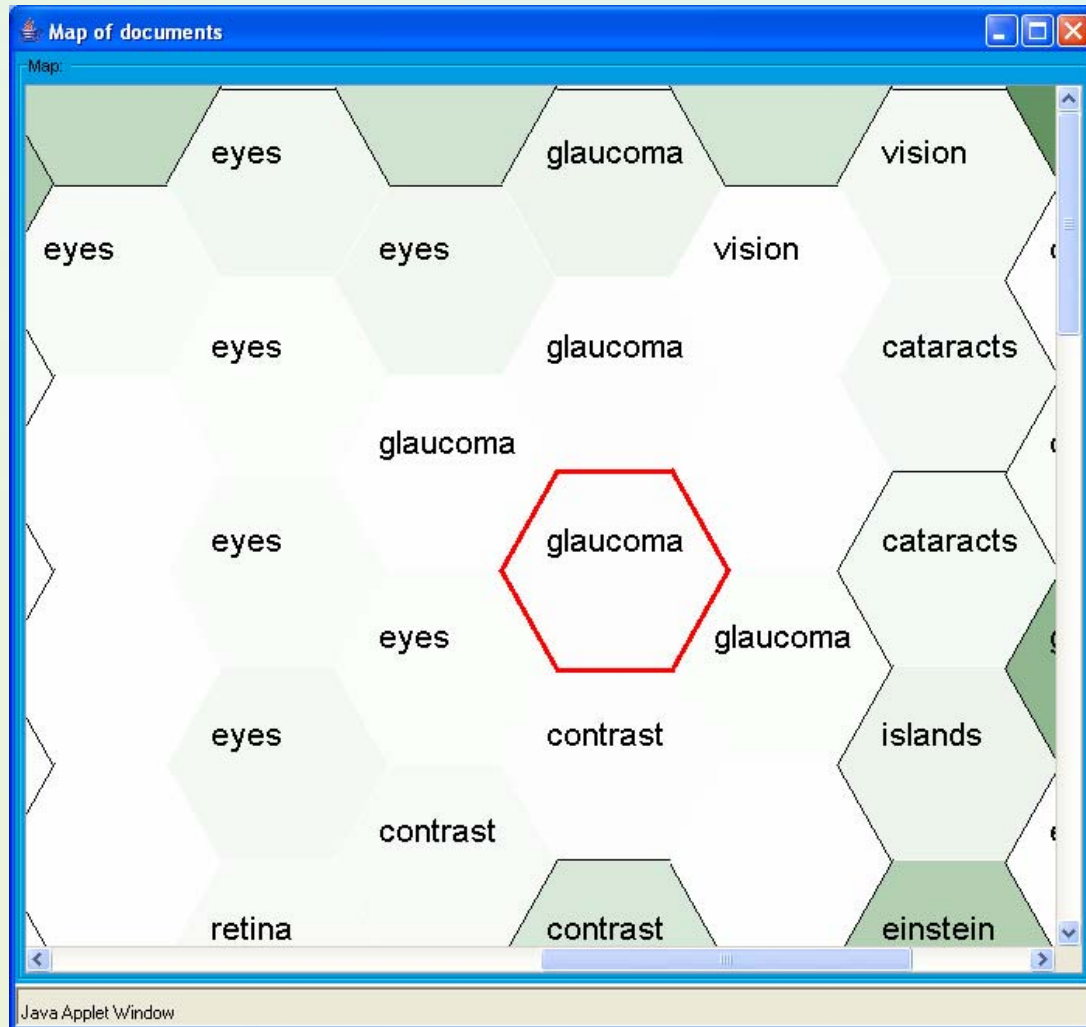
Documents: 2

1. [Health Diseases and Conditions Eye Conditions /4607](#)
Elevated IOP occurs when the clear fluid that nourishes the tissues of the eye does not drain properly, causing fluid buildup and subsequent pressure. There are several types of glaucoma: Open-angle(narrow-angle) the most common form of the disease, open-angle glaucoma is so named because the angle (between the cornea and the iris) where fluid is supposed to drain from the eye is open, but the fluid drains too slowly. Glaucoma Screening Open-angle glaucoma, the most common form of the disease, is often referred to as the "silent thief of **sight**" because there are no physical symptoms until vision loss occurs.
[file:///D:/Projekt KBN/Beatca/data/___Health_Diseases_and_Conditions_Eye_Co - null - Cached](#)
2. [Health Diseases and Conditions Eye Conditions /4677](#)
Elevated IOP occurs when the clear fluid that nourishes the tissues of the eye does not drain properly, causing fluid buildup and subsequent pressure. There are several types of glaucoma: Open-angle the most common form of the disease, open-angle glaucoma is so named because the angle (between the cornea and the iris) where fluid is supposed to drain from the eye is open, but the fluid drains too slowly. Open-angle glaucoma, the most common form of the disease, is often referred to as the "silent thief of **sight**" because there are no physical symptoms until vision loss occurs.
[file:///D:/Projekt KBN/Beatca/data/ Health_Diseases_and_Conditions_Eye_Co](#)

Applet beatca.visualization.Beatca started

Lokalny intranet

The traditional flat map - hexagonal



Hierarchical maps

Level 1



Level 2



Level 3

