
Sieci SOM Kohonena



JERZY STEFANOWSKI

Instytut Informatyki
Politechnika Poznańska
aktualiz. 2020

Plan

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



Samouczenie

- Samouczenie różni się od typowego uczenia tym że podczas samouczenia nie ma żadnego zewnętrznego źródła wiedzy (etykietyzacji, nauczyciela itp.), dostarczającego gotowe wiadomości, które wystarczy tylko sobie przyswoić
- Umysł samouczącego się człowieka, a także samoucząca się sieć neuronowa, musi najpierw sama odkryć wiedzę, którą następnie zapamięta.


Samouczenie w sieciach neuronowych

Reguła Hebba:

W neuro-fizjologii zauważono, że siła (waga) powiązań między dwoma neuronami wzrasta przy jednoczesnym pobudzeniu obu neuronów, w przeciwnym przypadku maleje. Zaobserwowano, że im częściej bodziec dochodzi do neuronu, tym silniejsza jest odpowiedź neuronu na ten bodziec.

$$w(k + 1) = w(k) + \Delta w(k)$$

$$w_{ij}(k+1) = w_{ij}(k) + \eta y_i x_j$$



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“.
 - 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)

Kohonen networks

Teuvo Kohonen...




... i jego
historyczne dzieło



- Podstawy teoretyczne Map Samoorganizujących się stworzył prof. Teuvo Kohonen (1982 r.)

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

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:

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


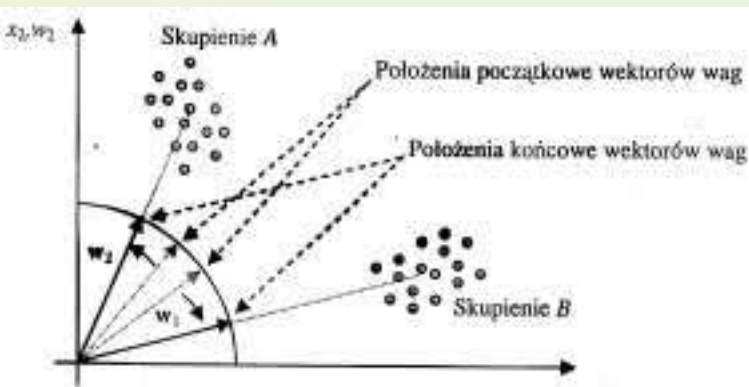
- η - stała uczenia (na ogół między 0.1 a 0.7)
- Przykład – interpretacja geometryczna

Uczenie zwycięskiego neuronu

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


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

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




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, MDS,...



Sieci SOM – Mapy samoorganizujące się


- Typ nienadzorowanej sieci neuronowej, która dokonuje projekcji danych wielowymiarowych do przestrzeni b. nisko wymiarowej (najczęściej dwu) nazywanej mapą.
- **Zachowanie sąsiedztwa punktów**
- Wizualizacja mapy -> pomaga odkryć ukrytą strukturę w danych
- Różnice do innych popularnych sieci – uczenie przez współzawodnictwo (the winner-take-all function).



Projekcja do przestrzeni 2D

o=dane

' = wagi sieci




przestrzeń cech

x y z

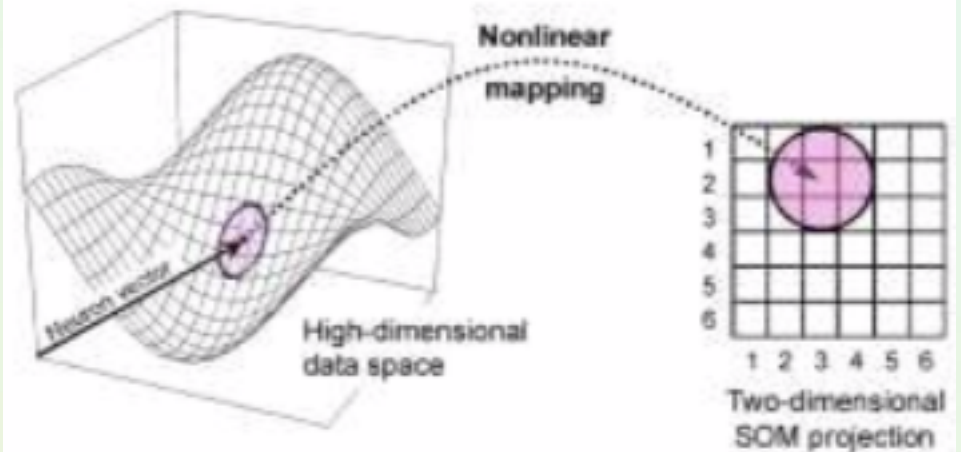
neurony wejściowe

wagi przypisane
połączeniom

2-D siatka
neuronów

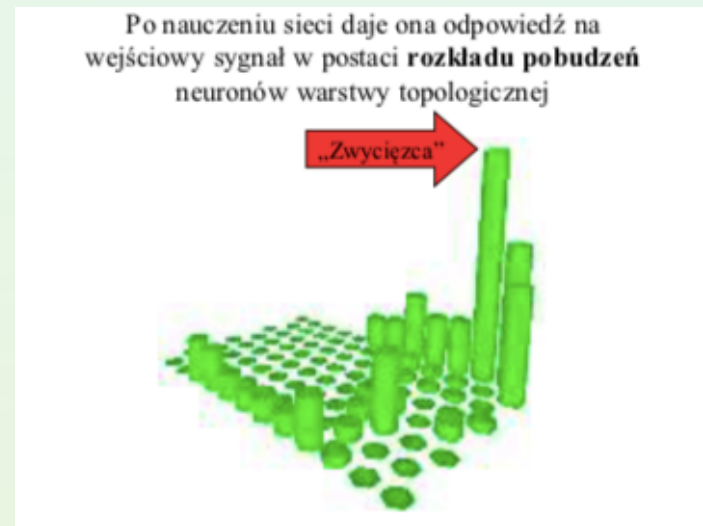


Typowe zastosowanie SOM

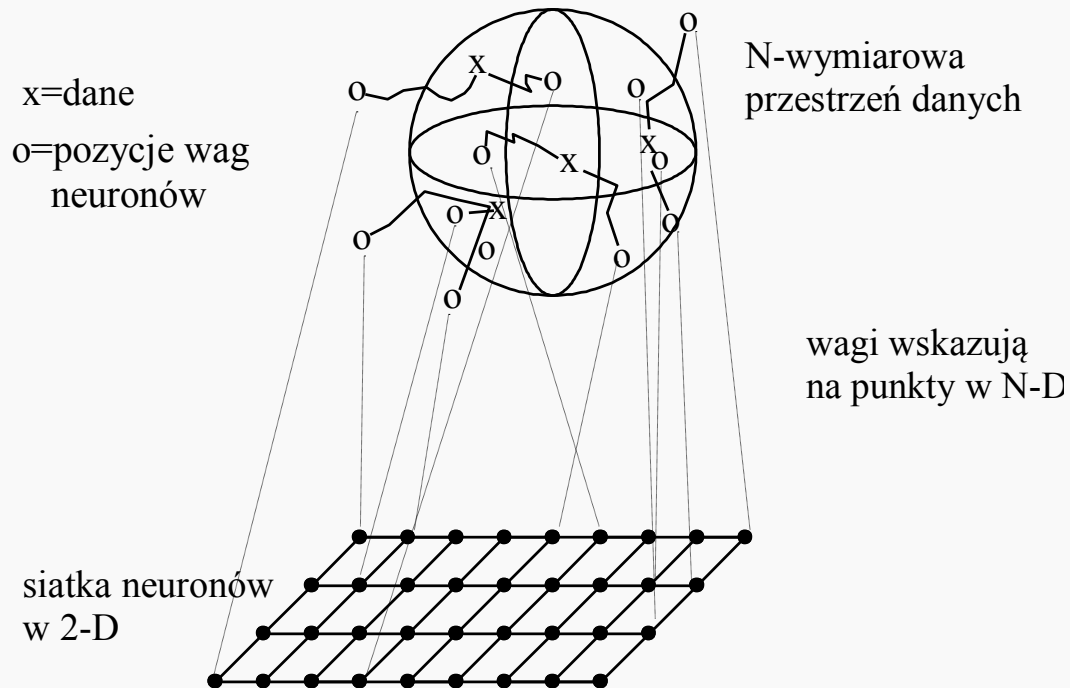


Sieci SOM

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



Zachowanie sąsiedztwa



Unsupervised Learning: Kohonen's Self-Organizing Map (SOM)

- 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

Własności sieci SOM

- The feature map Φ represented by the set of weight vectors $\{w_i\}$ in the output space, provides a good approximation to the input space.
- The feature map Φ computed by the SOM algorithm is topologically ordered in the sense that the spatial location of a neuron in the output lattice/grid corresponds to a particular domain or feature of the input patterns
- The feature map Φ reflects variations in the statistics of the input distribution: regions in the input space from which the sample training vectors x are drawn with high probability of occurrence are mapped onto larger domains of the output space, and therefore with better resolution than regions of input space from which training vectors are drawn with low probability
- Given data from an input space with a non-linear distribution, the self organizing map is able to select a set of best features for approximating the underlying distribution

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}

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}

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 $O(c)$:

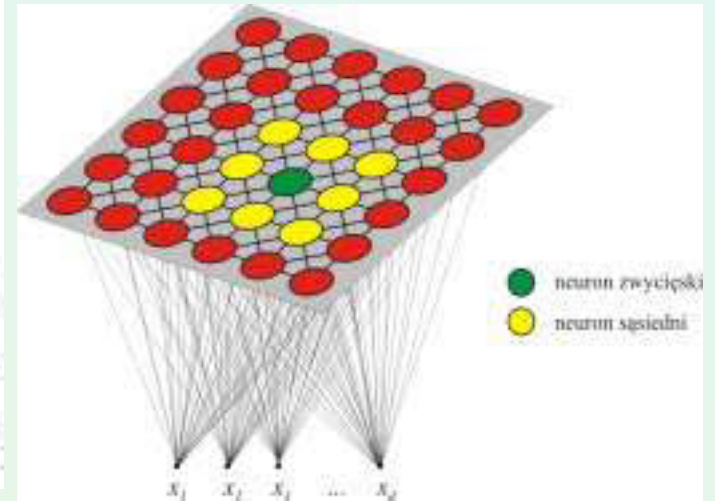
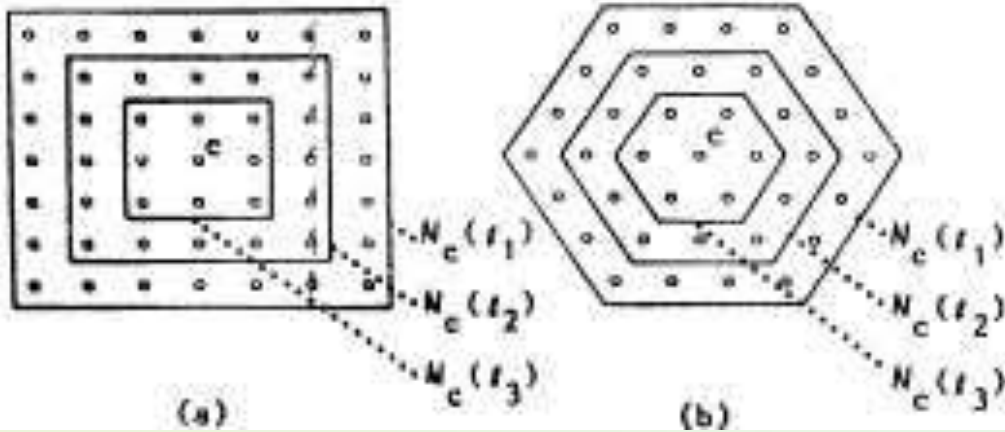
$$h(r, r_c, t) = h_0(t) \exp\left(-\|r - r_c\|^2 / \sigma_c^2(t)\right)$$

w stronę wektora \mathbf{X} :

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

Uczenie zwycięzcy i jego sąsiadów

$$h_{ci} = \alpha(t) \cdot \exp\left(-\frac{\|r_c - r_i\|^2}{2\sigma^2(t)}\right),$$



Za wykładem prof. Tadeusiewicza

Uczenie sieci 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.

Kalibracja neuronów po zakończeniu fazy uczenia

Faza użycia -> podaj przykład x i znajdź zwycięski neuron

Rozpoznawanie mowy w j. fińskim



Figure 13. Acoustic Preprocessing

After training resulting phonotopic map is shown in Fig. 14, [7]. During speech recognition new pattern vectors are assigned category belonging to a closest prototype in the map.




Figure 14. Phonotopic map, [7]

SOM Toolbox: Intro to SOM by Teuvo Kohonen - Windows Internet Explorer - [Praca w trybie offline]

E:\nowki\RBF\SOM Toolbox Intro to SOM by Teuvo Kohonen.htm

Plik Edycja Widok Ulubione Narzędzia Pomoc

SOM Toolbox: Intro to SOM by Teuvo Kohonen

Strona Narzędz

LABORATORY OF COMPUTER AND INFORMATION SCIENCE

ADAPTIVE INFORMATICS RESEARCH CENTRE

CIS

CIS Toolbox Home About Docs Download Links

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).


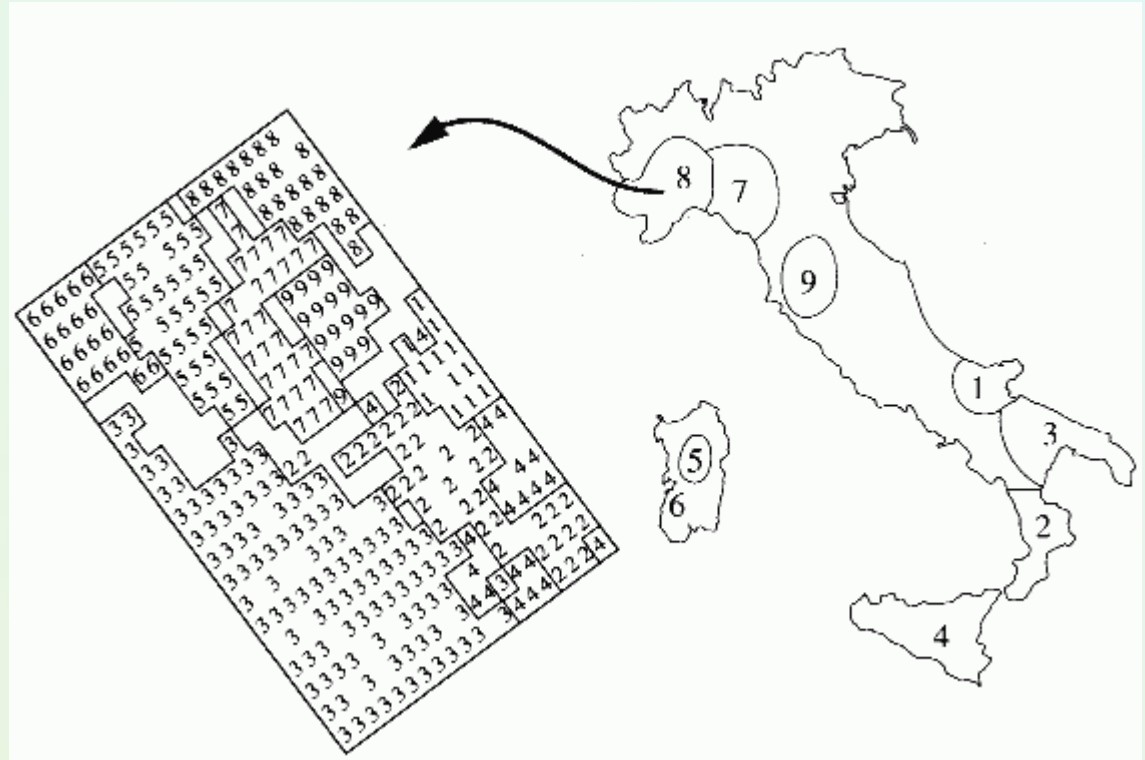


Figure 1: In this exemplary application, each processing element in the hexagonal grid holds a model of a short-time spectrum of natural speech (Finnish). Notice that neighboring models are mutually similar.

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.

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](#)).

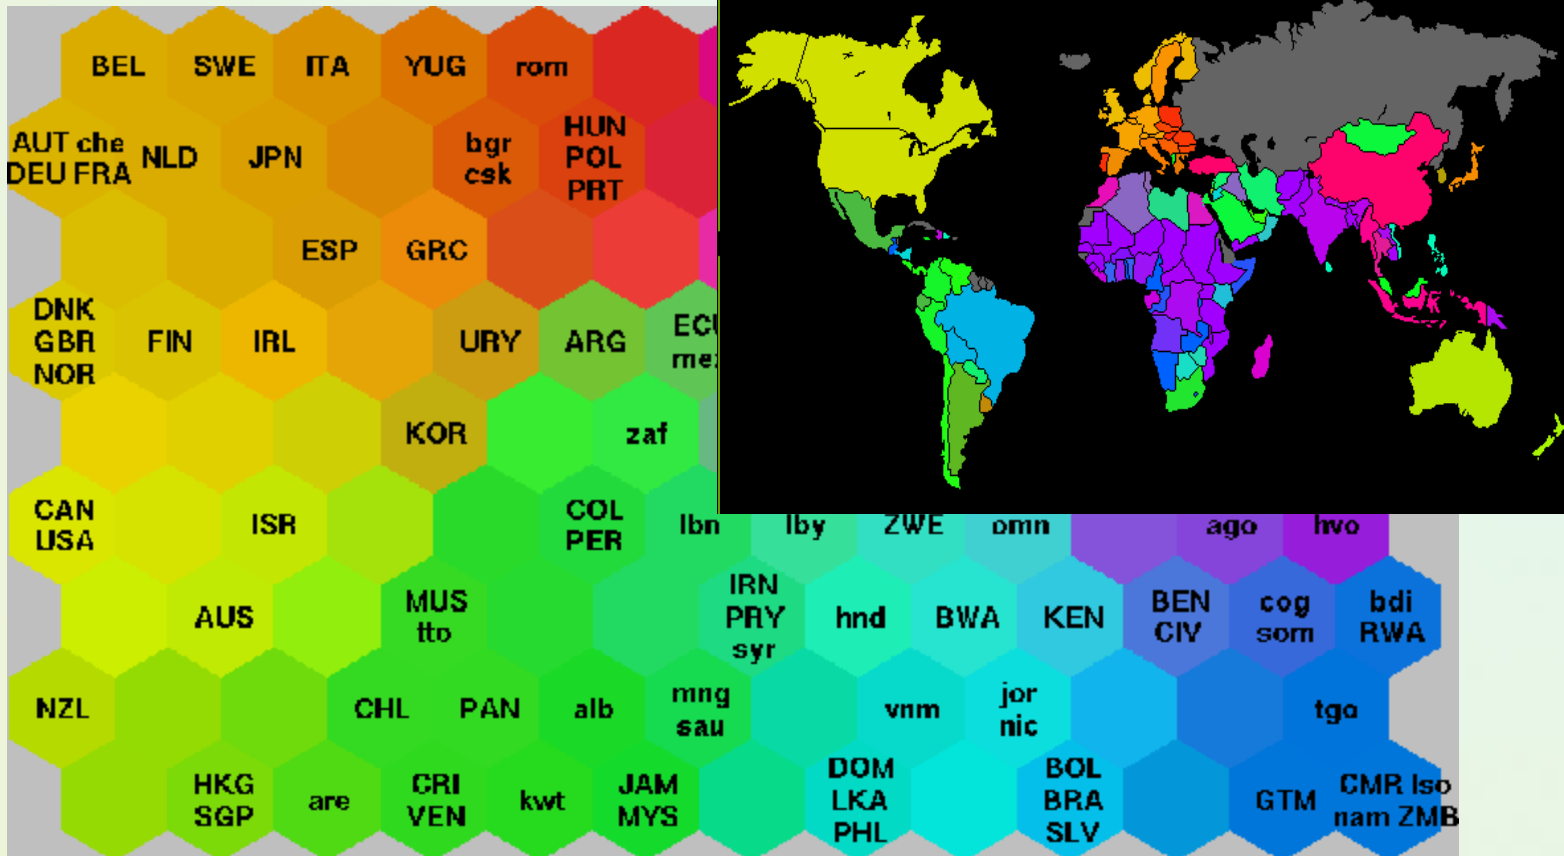


Quality of life data

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.eulerstics.com/>



Inne zastosowania

- 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.

Analiza kolekcji dokumentów

Wstępne przetworzenie i otrzymanie reprezentacji wektorowej (termy)

Zastosowanie do artykułów medycznych



Websom

WEBSOM:

- Własności klastrowania i odwzorowywania danych wejściowych SOM postanowiono wykorzystać w dziedzinie wyszukiwania informacji.
- Powstał w Centrum Badań nad Sieciami Neuronowymi (Helsinki University of Technology).
- Autor: prof. Teuvo Kohonen.
- Praktycznie można w niej umieścić nieskończoną ilość dokumentów.
- Z powodu dużej złożoności i czasochłonności procesu uczenia tworzone mapy mogą być jedynie statyczną prezentacją zbioru dokumentów stworzoną off-line.



WebSOM cd.

Eksperyment WebSom przeprowadzony w 1998 r. przez Kohonen'a:

- operował na zbiorze 1 124 134 dokumentów
- średnia długość dokumentu to 218 słów
- długość słownika wynosiła 63 773 słowa
- samoorganizująca się sieć składała się z 104 040 komórek
- materiał pochodził z 80 różnych grup tematycznych Usenet'u

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





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

Plik Edycja Widok Ulubione Narzędzia Pomoc

Wstecz Wyszukaj Ulubione

Adres <http://localhost:8080/beatca/> Przejdź Łącz

BEATCA Zoom: 1x Sphere 3D

glaucoma
eyes
glaucoma
eyes
glaucoma
eyes
glaucoma
contrast
eyes
contrast
retina
contrast

defect of sight Search

Collection of documents: **medical**

Map of indicated collection of documents:

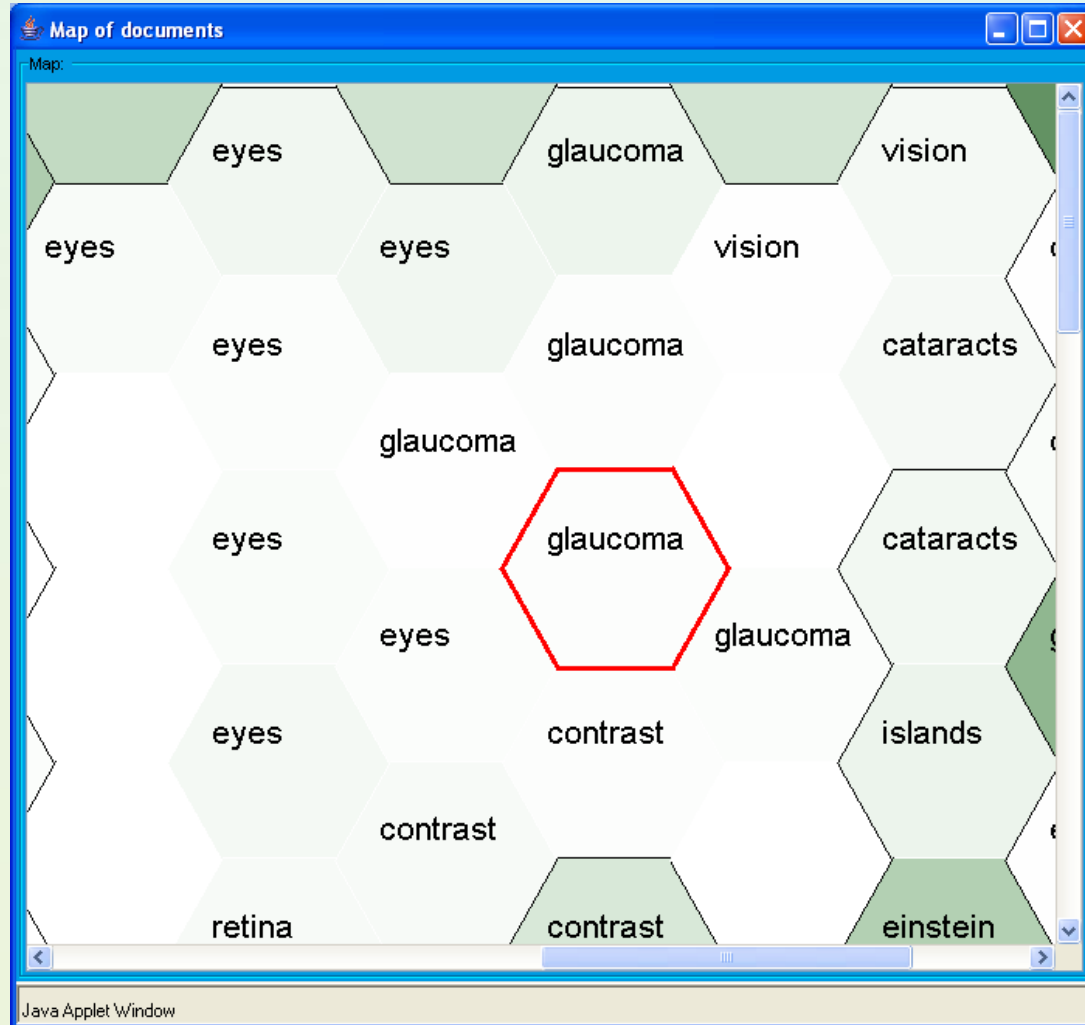
vectDB

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_Cor - 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_Cor

Applet beatca.visualization.Beatca started Lokalny intranet

The traditional flat map - hexagonal



Map visualizations in 3D

