



Growing neural Gas

Strukturen lernen

Torsten Siedel
23.05.2012

1. Prozess der Selbstorganisation
2. Lernen - momentan oder statistisch?
3. Vektorbasierte Neuronale Netze
4. Klassifizierung der Lernverfahren
5. Online Lernen
6. Neuronales Gas
7. Wachsendes Neuronales Gas
8. JAVA-Tool (Demonstration)
9. Beispiel aus der Natur

Prozess der Selbstorganisation



- Systemparameter sind von außen vorgegeben
- Genauer Endzustand des Systems vorher nicht bekannt
- Zustand entwickelt sich durch Selbstorganisation
- Einfluss von Einheiten meist nur durch „Nachbarn“
- Keine Zentrale Planung

Beispiel: Ökonomisches Gefüge eines Staates

Prozess der Selbstorganisation



Dynamische Selbstorganisation eines Vogelschwarms

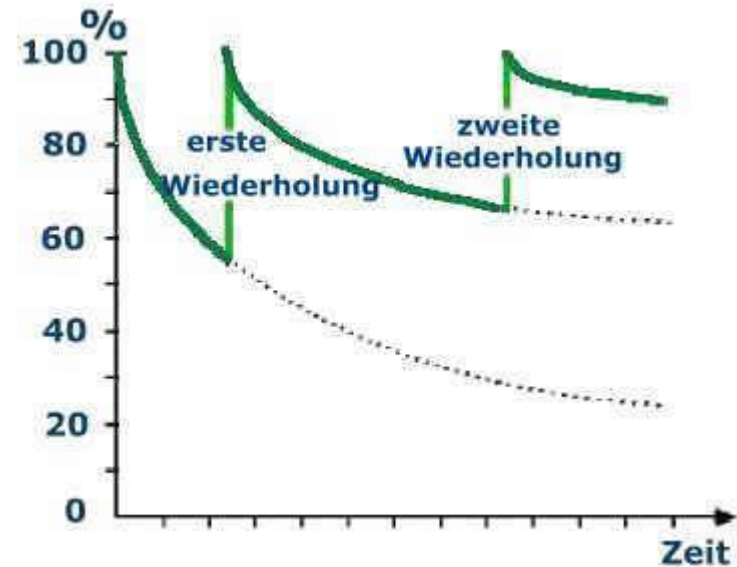
Lernen - momentan oder statistisch?

Momentanes Lernen



- Gesichtserkennung
- Gefahren


Statistisches Lernen



- Komplexe Bewegungsabläufe
- Kombinatorische Aufgaben

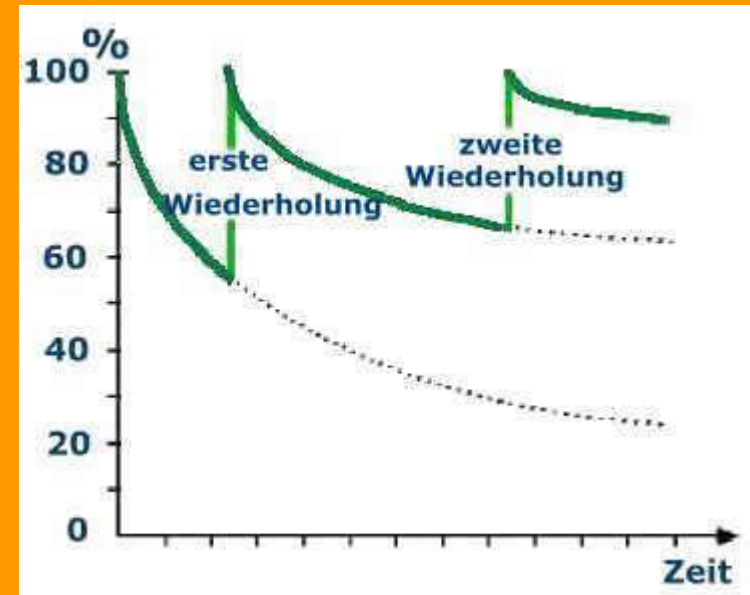
Lernen - momentan oder statistisch?

Momentanes Lernen



- Gesichtserkennung
- Gefahren

Statistisches Lernen



- Komplexe Bewegungsabläufe
- Kombinatorische Aufgaben

Vektorbasierte Neuronale Netze

Struktur

Der Netzzustand ist wesentlich durch eine Anzahl von n-dimensionalen Vektoren beschreiben, wobei n die Dimension des Eingaberaums ist. Diese Vektoren werden als Referenzvektoren bezeichnet.

Ein Netz besteht aus einer Menge $\mathcal{A} = \{c_1, \dots, c_N\}$ von Neuronen.

Ein Neuron entspricht einer „Einheit“

Jeder Einheit c ist der Referenzvektor $\mathbf{w}_c \in \mathbb{R}^n$ zugeordnet.

Vektorbasierte Neuronale Netze

Trainingsdaten


Kontinuierliche Wahrscheinlichkeitsverteilung

$$p(\boldsymbol{\xi}), \boldsymbol{\xi} \in \mathbb{R}^n$$



Endliche Menge

$$\mathcal{D} = \{\boldsymbol{\xi}^1, \dots, \boldsymbol{\xi}^M\}, \boldsymbol{\xi}^i \in \mathbb{R}^n.$$




Vektorbasierte Neuronale Netze

Gewinner


Der Gewinner ist die Einheit, die den *nächstgelegenen* Referenzvektor hat:

$$s(\xi) = \arg \min_{c \in \mathcal{A}} \|\xi - \mathbf{w}_c\|$$



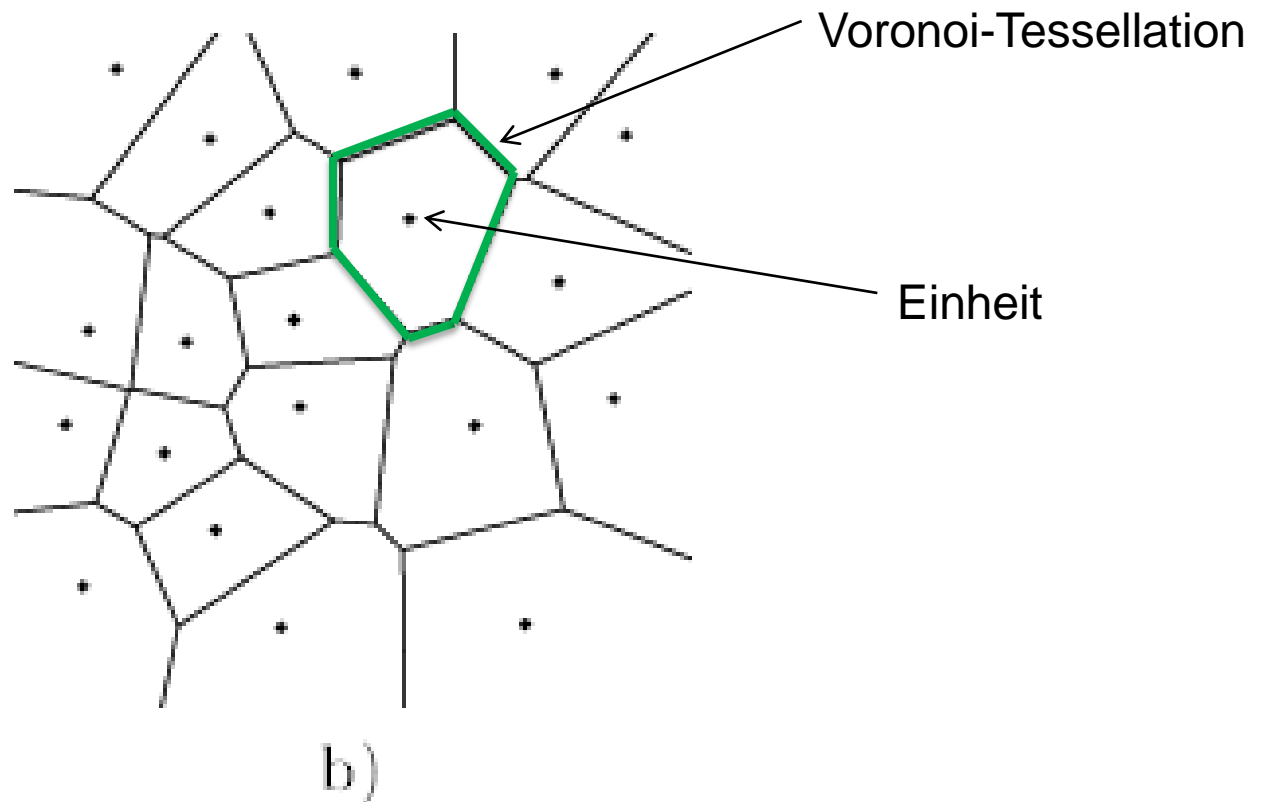
Vektorbasierte Neuronale Netze

Voronoi-Tessellation (b) und Delaunay-Triangulation (c)



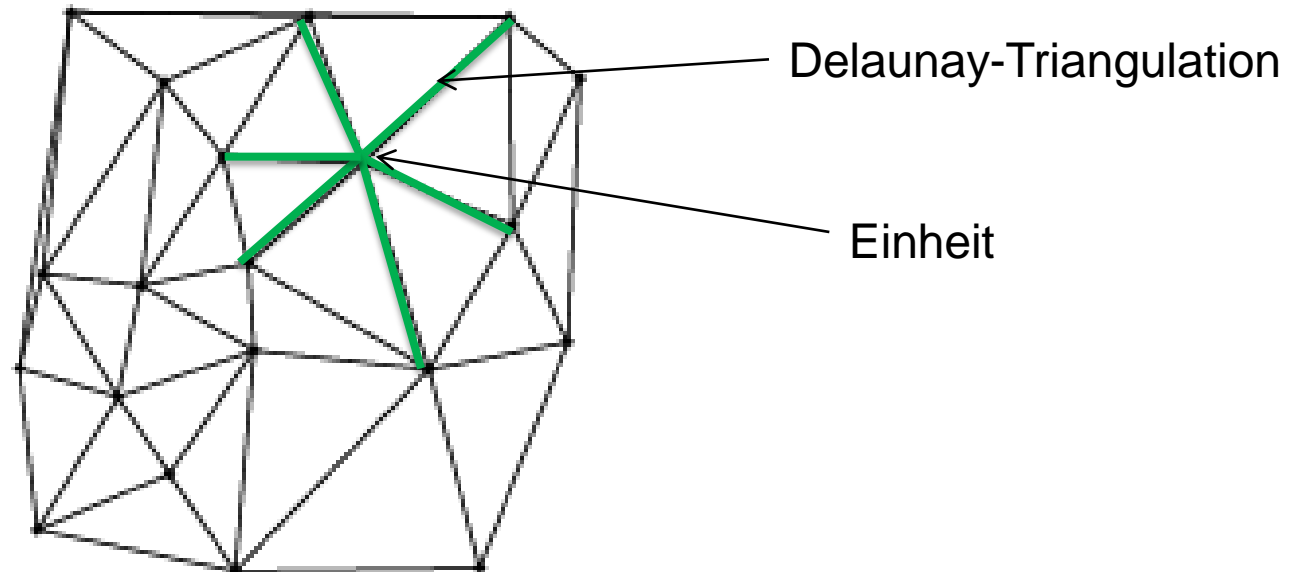
Vektorbasierte Neuronale Netze

Voronoi-Tessellation



Vektorbasierte Neuronale Netze

Delaunay-Triangulation



c)

Klassifizierung der Lernverfahren

Hartes Wettbewerbslernen für endliche Datenmengen

- LBG (Linde, Buzo, Gray)
- LBG-U (Fritzke)

Hartes Wettbewerbslernen für große und unendliche Datenmengen

- Hard Competitive Learning (standard)
- Competitive Hebbian Learning (Martinetz)

Weiches Wettbewerbslernen ohne feste Netzwerkdimension

- Neural Gas (Martinetz)
- Growing Neural Gas / GNG-U (Fritzke)
- Neural Gas with Competitive Hebbian Learning (Martinetz)

Weiches Wettbewerbslernen mit feste Netzwerkdimension

- Growing Grid (Fritzke)
- Self-Organizing Map (Kohonen)

Klassifizierung der Lernverfahren

Hartes Wettbewerbslernen für endliche Datenmengen

- LBG (Linde, Buzo, Gray)
- LBG-U (Fritzke)

Hartes Wettbewerbslernen für große und unendliche Datenmengen

- Hard Competitive Learning (standard)
- Competitive Hebbian Learning (Martinetz)


Weiches Wettbewerbslernen ohne feste Netzwerkdimension

- Neural Gas (Martinetz)
- Growing Neural Gas (Fritzke)
- Neural Gas with Competitive Hebbian Learning (Martinetz)


Weiches Wettbewerbslernen mit feste Netzwerkdimension

- Growing Grid (Fritzke)
- Self-Organizing Map (Kohonen)

Lernen mittels Voronoi-Tessellation



a) endliche Datenmenge




b) kontinuierliche W-Verteilung

Online Lernen


K-means-Lernen

$\epsilon_0 = \text{Lernrate}$

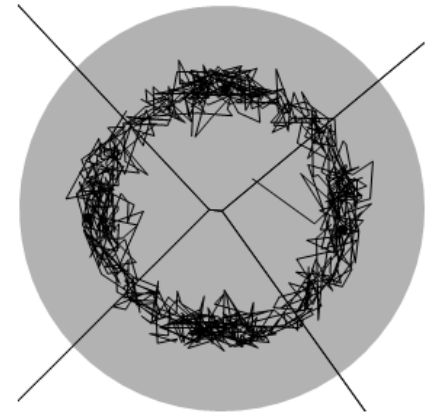
$$\mathbf{w}_s := \mathbf{w}_s + \epsilon(t)(\boldsymbol{\xi} - \mathbf{w}_s)$$



a) $\epsilon_0 = 0.001$






b) $\epsilon_0 = 0.01$




b) $\epsilon_0 = 0.1$

$\epsilon_0 = \text{gleich}$



$\epsilon_0 =$ Exponentiell abnehmend




Neuronales Gas

Lernrate $\epsilon(t) := \epsilon_i (\epsilon_f / \epsilon_i)^{t/t_{\max}},$


Lernrate $\lambda(t) := \lambda_i (\lambda_f / \lambda_i)^{t/t_{\max}},$

Nachbarschaftsreichweite $h(t, k) := \exp((1 - k) / \lambda(t))$


Adaptionstärke $\Delta \mathbf{w}_{s_k} := \epsilon(t) \cdot h(t, k) \cdot (\boldsymbol{\xi} - \mathbf{w}_{s_k})$




Neuronales Gas



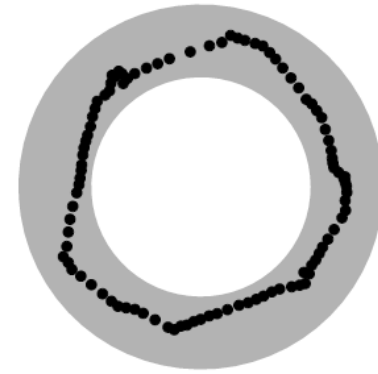
a) 0 Signale




b) 100 Signale




c) 300 Signale




d) 1000 Signale




e) 2500 Signale



f) 10000 Signale




g) 40000 Signale




h) Voronoigeometrie

Neuronales Gas


Hebb'sches Wettbewerbslernen -> Erzeugen einer Netztopologie




Neuronales Gas




a) 0 Signale




b) 100 Signale




c) 300 Signale




d) 1000 Signale




e) 2500 Signale



f) 10000 Signale



g) 40000 Signale




h) Voronoigeiete

Neuronales Gas


Hebb'schen
Wettbewerbslernen




Adaption der
Referenzvektoren
(Neuronales Gas)




a) 0 Signale




b) 100 Signale




c) 300 Signale




d) 1000 Signale




e) 2500 Signale



f) 10000 Signale



g) 40000 Signale



h) Voronoigebiete

Wachsendes Neuronales Gas

Problem

Üblicherweise *a priori* - Festlegen der Netzwerkgröße.

-> Viele Testdurchläufe notwendig um gewünschtes Netzwerk zu erzeugen

Wachstum

Start mit einem kleinem Netzwerk (z.B. nur zwei Einheiten)

Ende bei z.B. Erreichen eines mittleren Quantisierungsfehlers

Wachsendes Neuronales Gas

Problem

Üblicherweise *a priori* - Festlegen der Netzwerkgröße.

-> Viele Testdurchläufe notwendig um gewünschtes Netzwerk zu erzeugen

Wachstum

Start mit einem kleinem Netzwerk (z.B. nur zwei Einheiten)

Ende bei z.B. Erreichen eines mittleren Quantisierungsfehlers

Fehlergröße soll reduziert werden.

$$\sum_{c \in \mathcal{A}} E_c \quad \text{min!}$$

Absenke des Fehlers durch Einfügen einer neuen Einheit.


$$\sum_{c \in \mathcal{A}} E_c > \sum_{c \in \mathcal{A} \cup \{r\}} E_c$$

Stärkste Absenkung des Fehlers, durch Einfügen bei Einheit mit dem größten Fehler.


$$q := \arg \max_{c \in \mathcal{A}} E_c.$$

Wachsendes Neuronales Gas


Hebb'schen
Wettbewerbslernen




Adaption der
Referenzvektoren
(Neuronales Gas)




Wachstum




a) 0 Signale




b) 100 Signale




c) 300 Signale




d) 1000 Signale




e) 2500 Signale



f) 10000 Signale



g) 40000 Signale

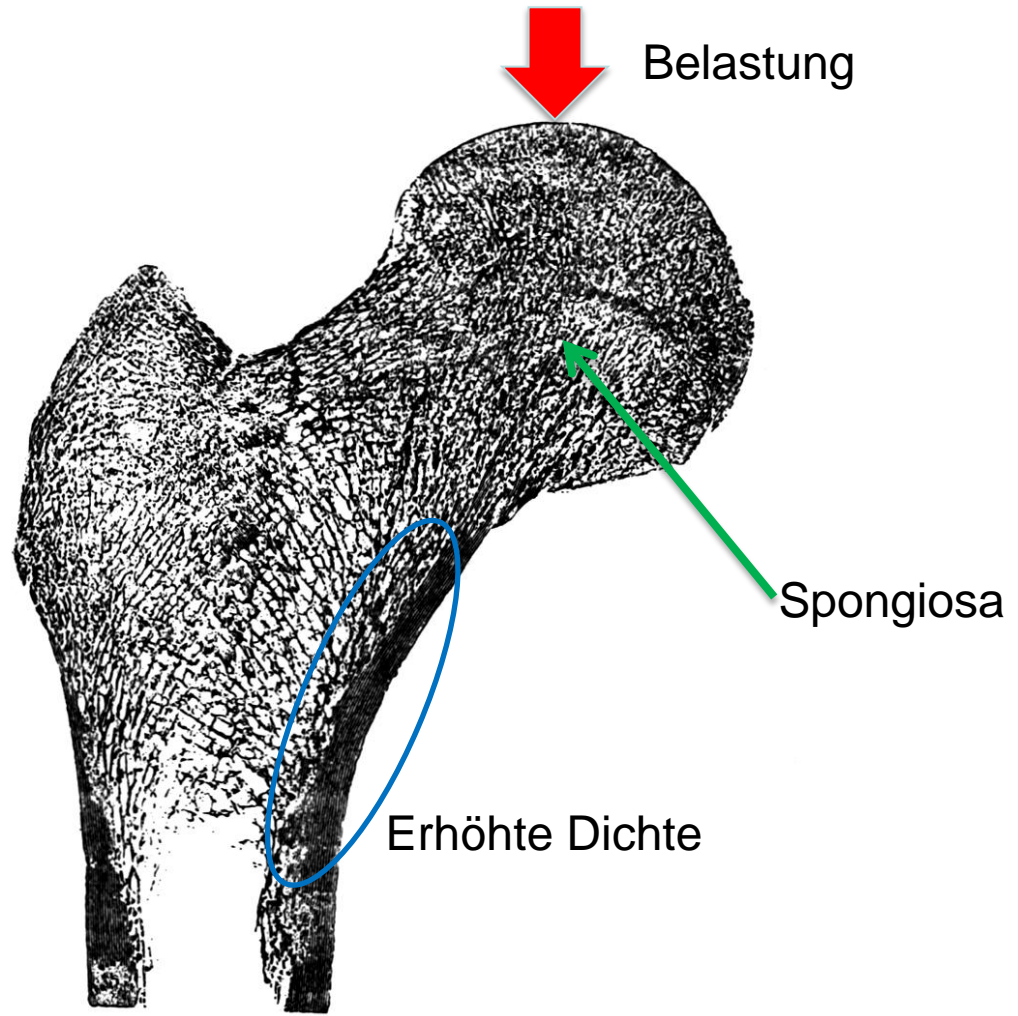


h) Voronoigeiete

Demonstration

JAVA-Tool

Beispiel aus der Natur



Beispiel aus der Natur



Beispiel aus der Natur



Beispiel aus der Natur



Beispiel aus der Natur



Beispiel aus der Natur



Quellen

Fritzke, B.:

Vektorbasierte Neuronale Netze. Erlangen, Friedrich-Alexander-Universität Erlangen-Nürnberg, Habilitation, 1998.

Fritzke, B.:

Wachsende Zellstrukturen - ein selbstorganisierendes neuronales Netzwerkmodell. Erlangen, Friedrich-Alexander-Universität Erlangen-Nürnberg, Dissertation, 1992.

Java-Programm DemoGNG zur Simulation von Neuronalen Netzen:

http://sund.de/netze/applets/gng/full/GNG-U_0.html



**Danke für Euer
Zuhören**

... nun zur Diskussion