

# Neuronale Netze

Prof. Dr. Rudolf Kruse

Computational Intelligence  
Institut für Intelligente Kooperierende Systeme  
Fakultät für Informatik  
[kruse@iws.cs.uni-magdeburg.de](mailto:kruse@iws.cs.uni-magdeburg.de)



# Neuro-Fuzzy-Systeme

Nachteil neuronaler Netze:

- Ergebnisse sind schlecht interpretierbar (black box)
- Vorwissen kann schlecht dargestellt werden

Ausweg:

- hybrides System, bei dem NN mit einem regelbasierten System gekoppelt sind
- ein mögliches Verfahren: Neuro-Fuzzy-Systeme

# Kurzeinführung in die Fuzzy-Theorie

**Klassische Logik:** nur Wahrheitswerte *wahr* und *falsch*

**Klassische Mengenlehre:** entweder *ist Element* oder *nicht*

Zweiwertigkeit dieser Theorien: oft unangemessen

Beispiel: **Sorites-Paradoxon** (griech. *sorites*: Haufen)

*wahr*: “Eine Milliarde Sandkörner sind ein Sandhaufen.”

*wahr*: “Wenn man von einem Sandhaufen ein Sandkorn entfernt,  
bleibt ein Sandhaufen übrig.”

*wahr*: 999 999 999 “Sandkörner sind ein Sandhaufen.”

mehrfache Wiederholung des gleichen Schlusses:

*falsch*: “1 Sandkorn ist ein Sandhaufen.”

Frage: Bei welcher Anzahl Sandkörner ist Schluss nicht wahrheitsbewahrend?

# Kurzeinführung in die Fuzzy-Theorie

Offenbar: keine genau bestimmte Anzahl Sandkörner, bei der der Schluss auf nächstkleinere Anzahl falsch ist

Problem: Begriffe der natürlichen Sprache (z.B. “Sandhaufen”, “kahlköpfig”, “warm”, “schnell”, “hoher Druck”, “leicht” etc.) sind **vage**

Beachte: vage Begriffe sind *unexakt*, aber nicht *unbrauchbar*

- Auch für vage Begriffe: Situationen/Objekte, auf die sie *sicher anwendbar* sind und solche, auf die sie *sicher nicht anwendbar* sind
- Dazwischen: **Penumbra** (lat. für *Halbschatten*) von Situationen, in denen es unklar ist, ob die Begriffe anwendbar sind, oder in denen sie nur mit Einschränkungen anwendbar sind (“kleiner Sandhaufen”).
- Fuzzy-Theorie: mathematische Modellierung der Penumbra

Erweiterung der klassischen Logik um Zwischenwerte zwischen *wahr* und *falsch*

Wahrheitswert: jeder Wert aus  $[0, 1]$ , wobei  $0 \hat{=} falsch$  und  $1 \hat{=} wahr$

## Erweiterung der logischen Operatoren

Klassische Logik		Fuzzy-Logik		
Operation	Notation	Operation	Notation	Beispiel
Negation	$\neg a$	Fuzzy-Negation	$\sim a$	$1 - a$
Konjunktion	$a \wedge b$	$t$ -Norm	$\top(a, b)$	$\min(a, b)$
Disjunktion	$a \vee b$	$t$ -Konorm	$\perp(a, b)$	$\max(a, b)$

### Grundprinzipien der Erweiterung:

- Für Extremwerte 0 und 1 sollen sich Operationen genauso verhalten wie ihre klassischen Vorbilder (Rand-/Eckbedingungen)
- Für Zwischenwerte soll ihr Verhalten monoton sein
- Gesetze der klassischen Logik sollen (fast alle) erhalten werden

# Fuzzy-Mengenlehre

Klassische Mengenlehre basiert auf Begriff “*ist Element von*” ( $\in$ )

Alternativ: Zugehörigkeit zu Menge mit *Indikatorfunktion* beschreibbar: sei  $X$  eine Menge, dann heißt

$$I_M : X \rightarrow \{0, 1\}, \quad I_M(x) = \begin{cases} 1, & \text{falls } x \in X, \\ 0, & \text{sonst,} \end{cases}$$

**Indikatorfunktion** der Menge  $M$  bzgl. Grundmenge  $X$

In Fuzzy-Mengenlehre: ersetze Indikatorfunktion durch *Zugehörigkeitsfunktion*: sei  $X$  (klassische/scharfe) Menge, dann heißt

$$\mu_M : X \rightarrow [0, 1], \quad \mu_M(x) \hat{=} \text{Zugehörigkeitsgrad von } x \text{ zu } M,$$

**Zugehörigkeitsfunktion** (membership function) der **Fuzzy-Menge**  $M$  bzgl. der *Grundmenge*  $X$

Fuzzy-Menge: definiert über ihre Zugehörigkeitsfunktion

# Formale Definition einer Fuzzy-Menge

1. Eine Fuzzy-Menge  $\mu \in X \neq \emptyset$  ist eine Funktion, die aus der Referenzmenge  $X$  in das Einheitsintervall abbildet, d.h.  $\mu : X \rightarrow [0, 1]$ .
2.  $\mathcal{F}(X)$  stellt die Menge aller Fuzzy-Mengen von  $X$  dar, d.h.  $\mathcal{F}(X) \stackrel{\text{def}}{=} \{\mu \mid \mu : X \rightarrow [0, 1]\}$ .

# Fuzzy-Partitionen und Linguistische Variablen

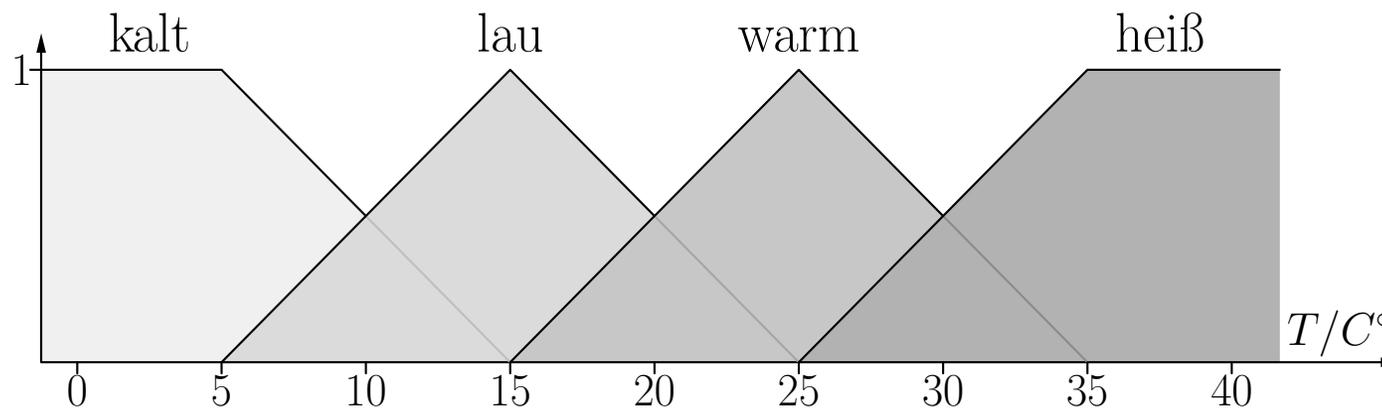
Um Wertebereich durch sprachliche (linguistische) Ausdrücke beschreiben zu können, wird er mithilfe von Fuzzy-Mengen fuzzy-partitioniert

Jeder Fuzzy-Menge der Partitionierung ist ein linguistischer Term zugeordnet

Übliche Bedingung: an jedem Punkt müssen sich Zugehörigkeitsgrade aller Fuzzy-Mengen zu 1 addieren

**Beispiel:** Fuzzy-Partitionierung für Temperaturen

Linguistische Variable mit den Werten *kalt*, *lau*, *warm* und *heiß*.



# Operationen

Wie beim Übergang von klassischer Logik zur Fuzzy-Logik: hier auch Erweiterung der Operationen nötig

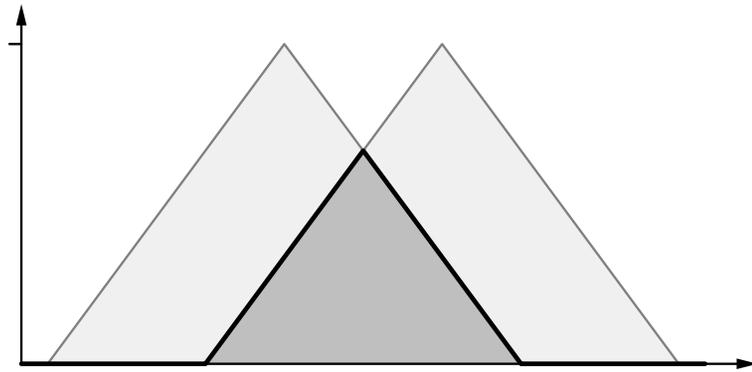
**Grundprinzip dieser Erweiterung:** greife auf logische Definition der Operationen zurück

Elementweise Anwendung der logischen Operatoren

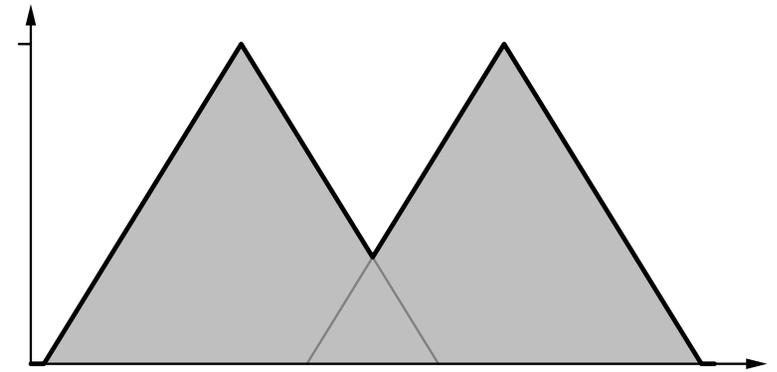
(Fuzzy-)Mengen  $A$  und  $B$  über Grundmenge  $X$

<b>Komplement</b>	klassisch	$\bar{A} = \{x \in X \mid x \notin A\}$
	fuzzy	$\forall x \in X: \mu_{\bar{A}}(x) = \sim\mu_A(x)$
<b>Schnitt</b>	klassisch	$A \cap B = \{x \in X \mid x \in A \wedge x \in B\}$
	fuzzy	$\forall x \in X: \mu_{A \cap B}(x) = \top(\mu_A(x), \mu_B(x))$
<b>Vereinigung</b>	klassisch	$A \cup B = \{x \in X \mid x \in A \vee x \in B\}$
	fuzzy	$\forall x \in X: \mu_{A \cup B}(x) = \perp(\mu_A(x), \mu_B(x))$

# Beispiele für Fuzzy-Schnitt und Fuzzy-Vereinigung



Fuzzy-Schnitt (min)



Fuzzy-Vereinigung (max)

Unterteilung in kooperative und hybride Modelle

## **Kooperative Modelle:**

- Neuronales Netz und Fuzzy-Regler operieren getrennt voneinander
- Neuronales Netz generiert (offline) oder optimiert (online) gewisse Parameter

## **Hybride Modelle:**

- Vereinigen die Strukturen eines neuronalen Netzes und eines Fuzzy-Reglers
- Hybrider Neuro-Fuzzy-Regler kann als eines neuronales Netz interpretiert und mithilfe eines neuronalen Netzes implementiert werden
- Vorteile: integrierte Struktur, keine Kommunikation zw. zwei verschiedenen Modelle notwendig, prinzipiell sind Online- und Offline-Lernen möglich
- Haben sich eher durchgesetzt als kooperative Modelle

# Fallstudie: Aktienkursvorhersage

Prognose der täglichen relativen Änderungen des DAX, aufbauend auf Zeitreihen von Börsen-Indizes im Zeitraum von 1986 bis 1997

DAX	Composite-DAX
German 3 months interest rate	Return Germany
German Morgan-Stanley index	Dow Jones industrial index
DM / US-\$	US treasure bonds
gold price	Japanese Nikkei-Index
European Morgan-Stanley-Index	Price earning ratio

# Fuzzy-Regeln im Finanzbereich

trend rule

IF DAX = decreasing AND US-\$ = decreasing  
THEN DAX prediction = decreasing  
WITH high certainty

turning point rule

IF DAX = decreasing AND US-\$ = increasing  
THEN DAX prediction = increasing  
WITH low certainty

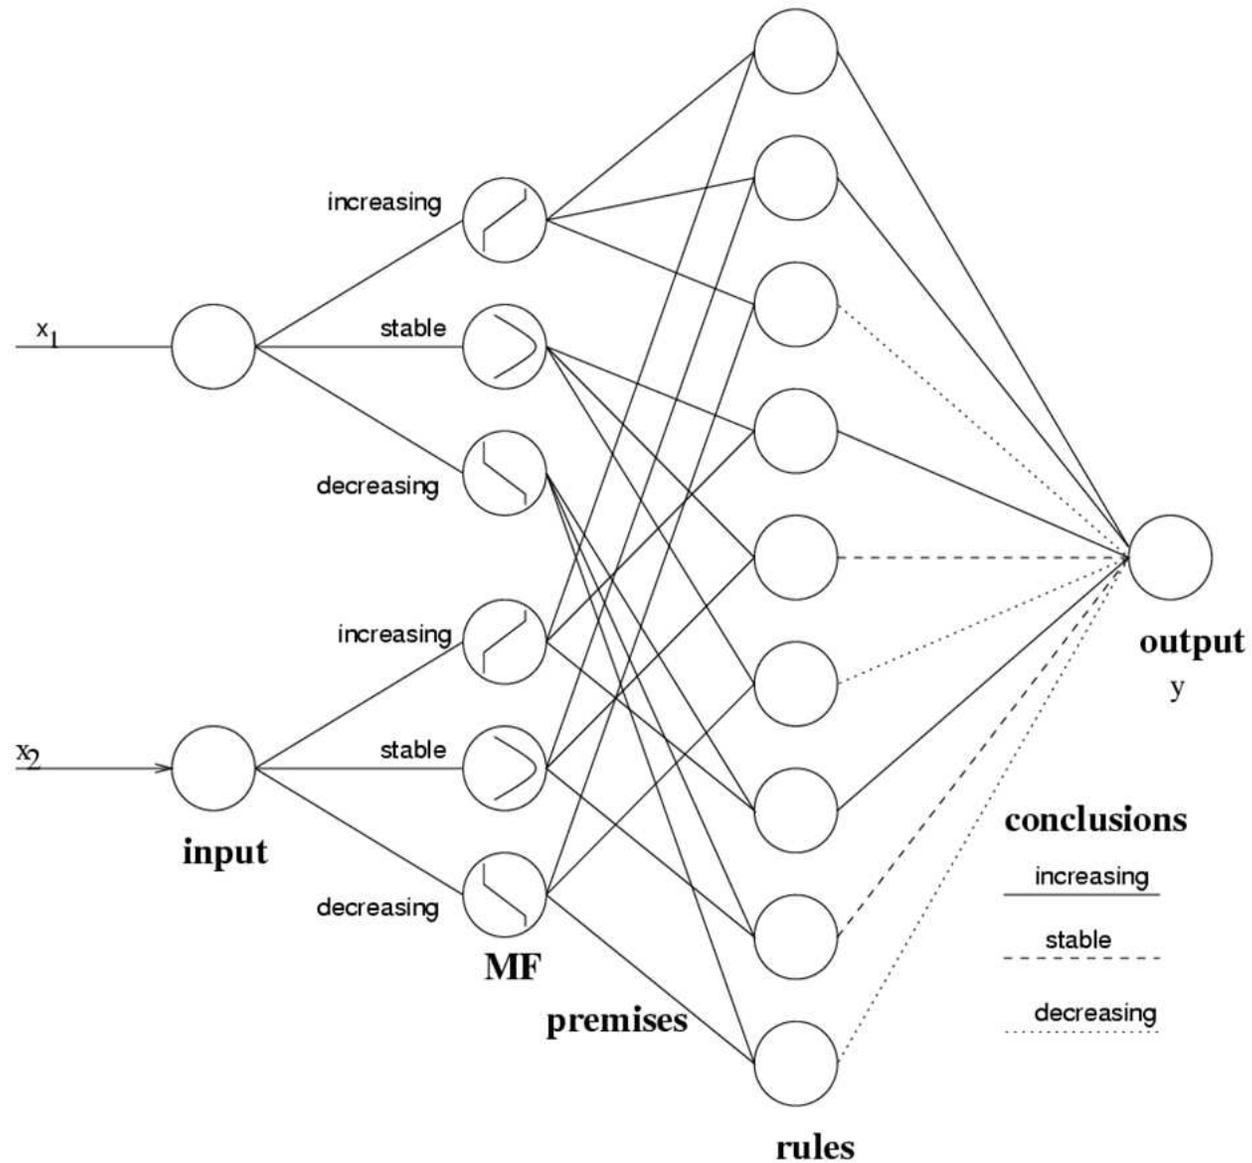
delay rule

IF DAX = stable AND US-\$ = decreasing  
THEN DAX prognosis = decreasing  
WITH very high certainty

in general

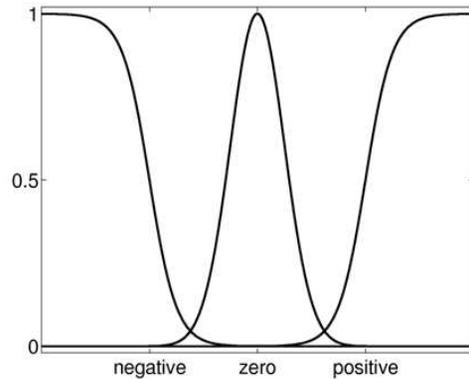
IF  $x_1$  is  $\mu_1$  AND  $x_2$  is  $\mu_2$  AND ... AND  $x_n$  is  $\mu_n$   
THEN  $y = \eta$   
WITH weight  $k$

# Neuro-Fuzzy-Architektur



# Von Regeln zu Neuronalen Netzen

## 1. Bewertung von Zugehörigkeitsgraden



## 2. Bewertung von Regeln (Regelaktivität)

$$\mu_l = \mathbb{R}^n \rightarrow [0, 1]^r, \quad \underline{x} \Rightarrow \prod_{j=1}^{D_l} \mu_{c,s}^{(j)}(x_i)$$

## 3. Akkumulation von Regeleingaben, Normalisierung

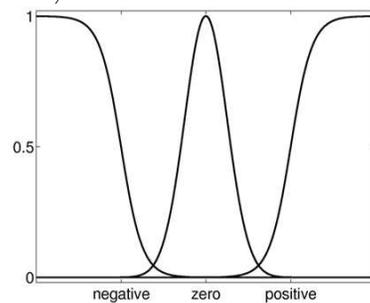
$$\text{NF} : \mathbb{R}^n \rightarrow \mathbb{R}, \quad \underline{x} \Rightarrow \sum_{l=1}^r w_l \frac{k_l \mu_l(\underline{x})}{\sum_{j=1}^r k_j \mu_j(\underline{x})}$$

# Dimensionsreduktion des Gewichtsraums

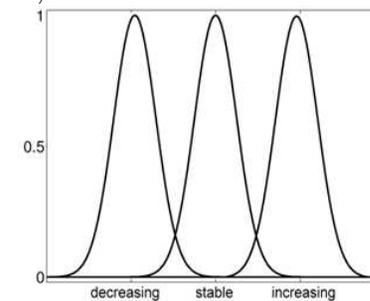
1. Zugehörigkeitsfunktionen verschiedener Eingaben teilen ihre Parameter untereinander, z.B.

$$\mu_{\text{DAX}}^{\text{stabil}} = \mu_{\text{C-DAX}}^{\text{stabil}}$$

2. Zugehörigkeitsfunktionen derselben Eingabevariable dürfen nicht einander passieren, sondern müssen ihre Originalreihenfolge beibehalten, d.h.



$$\mu_{\text{decreasing}} < \mu_{\text{stable}} < \mu_{\text{increasing}}$$



Vorteile:

- Die optimierte Regelbasis ist immer noch interpretierbar.
- Die Anzahl freier Parameter wurde reduziert.

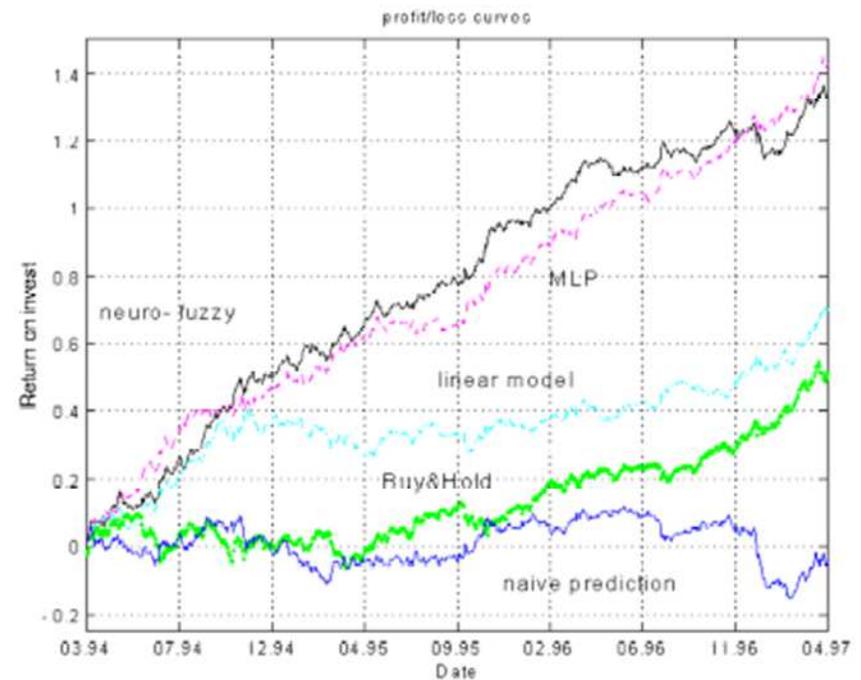
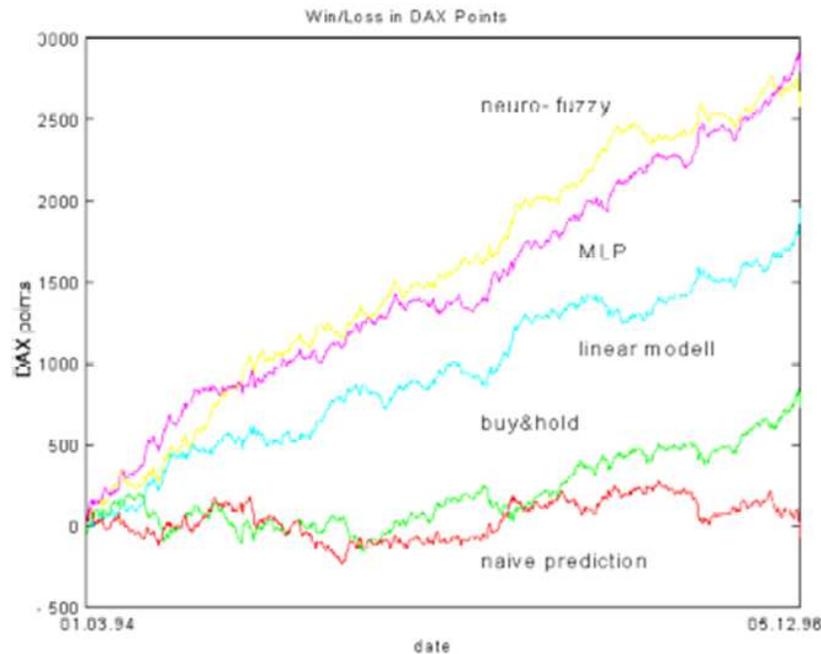
- Die Parameter der Fuzzy-Mengen,
- die Gewichte
- die Regelwichtigkeiten

werden durch ein Backpropagation-Verfahren ermittelt. Es werden Pruning-Verfahren genutzt.

# Gewinnkurven

Verschiedene Modelle

Validierungsdaten: März 1994 bis April 1997



# Fallstudie: medizinische Diagnose nach NEFCLASS-Einführung

Ergebnisse von Patienten, die auf Brustkrebs getestet wurden (Wisconsin Breast Cancer Data)

Entscheidungsunterstützung: liegt ein gutartiger oder bösartiger Fall vor?

Ein Chirurg muss die Klassifikation auf ihre Plausibilität hin überprüfen können.

Es wird nach einem einfachen und interpretierbaren Klassifikator gesucht

# Fallstudie: WBC-Daten

699 Fälle (16 Fälle mit fehlenden Werten)

2 Klassen: gutartig(458), bösartig (241)

9 Attribute mit Werten in  $\{1, \dots, 10\}$  (ordinale Skala, aber normalerweise numerisch interpretiert)

Experiment:  $x_3$  und  $x_6$  werden als nominale Attribute interpretiert

$x_3$  und  $x_6$  werden oft als “wichtige” Attribute angesehen

# Anwendung von NEFCLASS-J

Werkzeug zur Entwicklung von  
Neuro-Fuzzy-Klassifikatoren

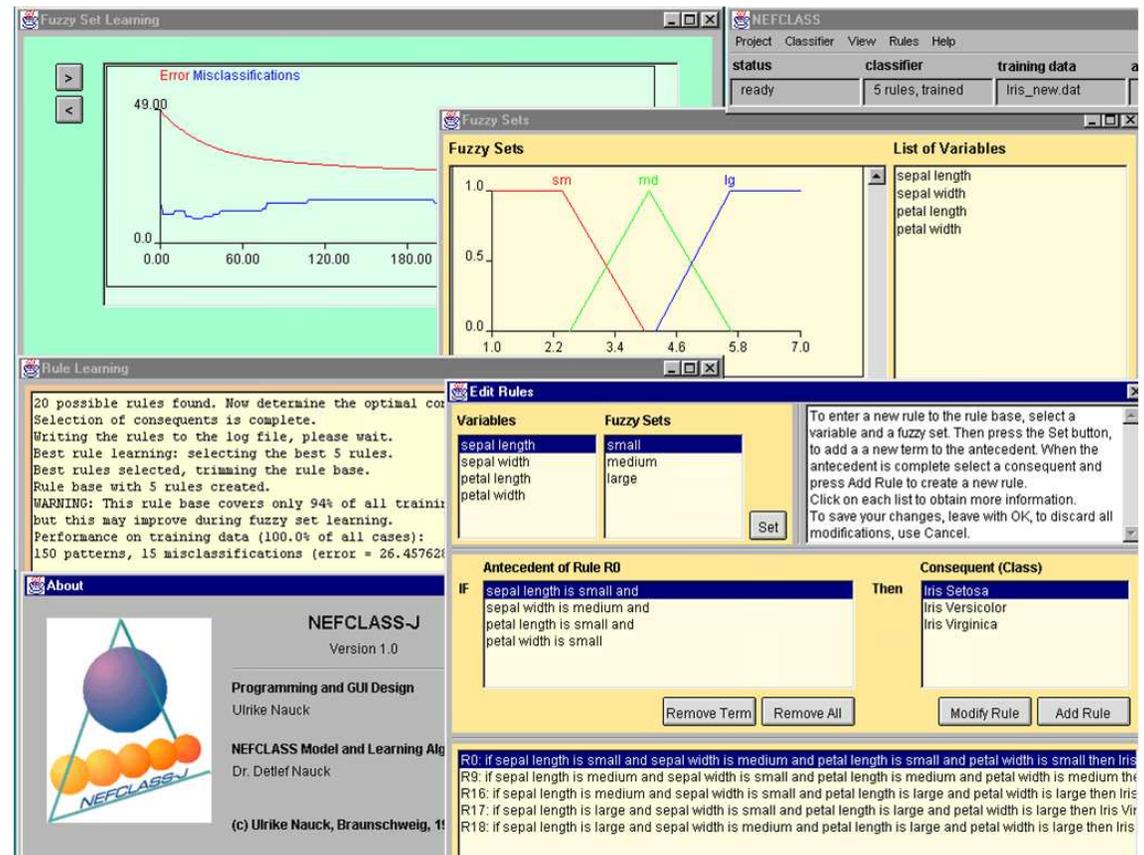
Java-Implementierung

frei verfügbar

zu Forschungszwecken

Projekt in unserer

Gruppe gestartet



<http://fuzzy.cs.ovgu.de/nefclass/nefclass-j/>

# NEFCLASS: Neuro-Fuzzy-Klassifikator

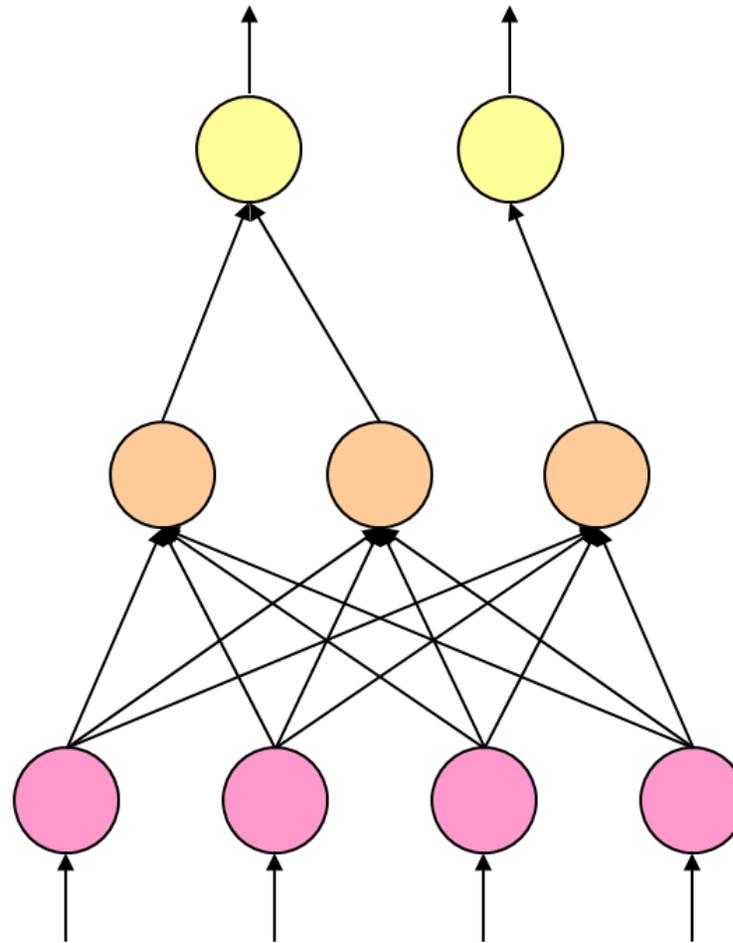
Ausgabevariablen

ungewichtete Verbindungen

Fuzzy-Regeln

Fuzzy-Mengen (Antezedens)

Eingabeattribute (Variablen)



# Darstellung von Fuzzy-Regeln

Beispiel: 2 Regeln

$R_1$  : if  $x$  is *large* and  $y$  is *small*, then class is  $c_1$

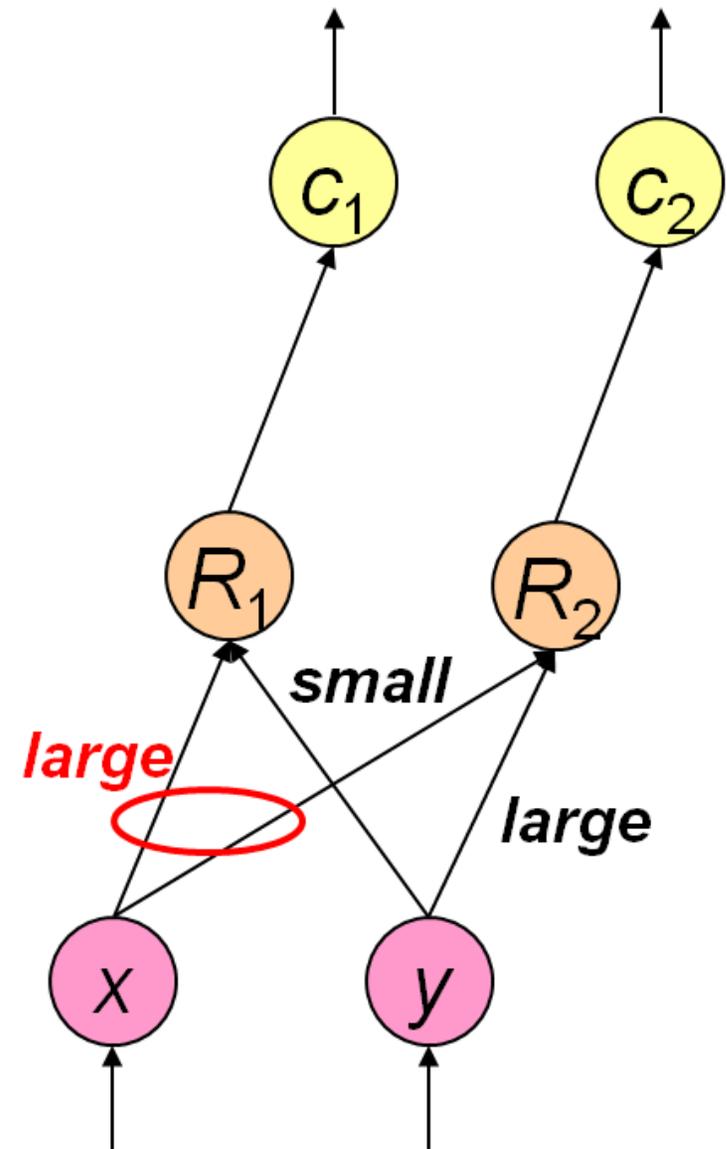
$R_2$  : if  $x$  is *large* and  $y$  is *large*, then class is  $c_2$

Verbindungen  $x \rightarrow R_1$  und  $x \rightarrow R_2$  sind verbu

Fuzzymenge *large* teilt Gewicht auf

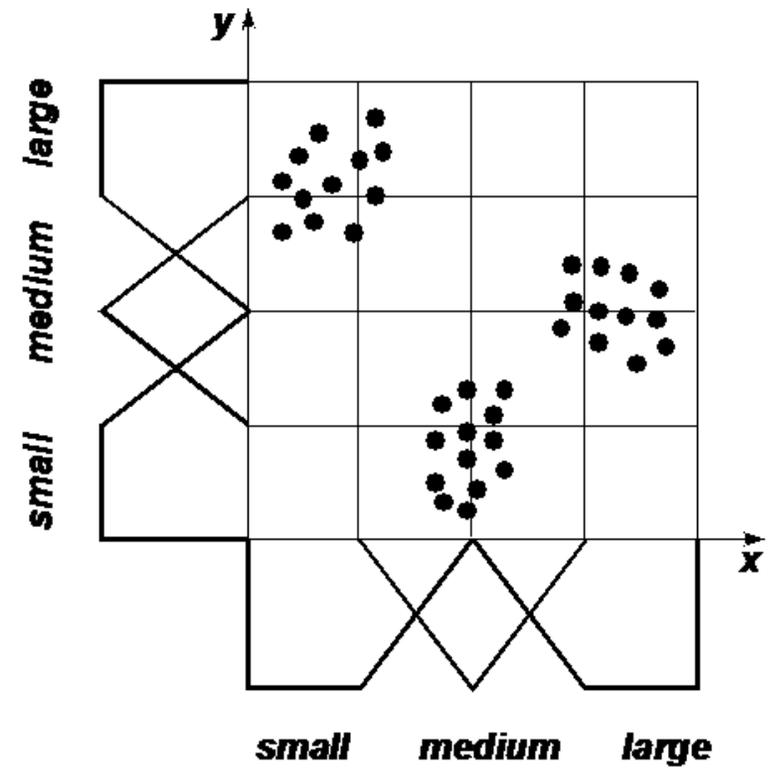
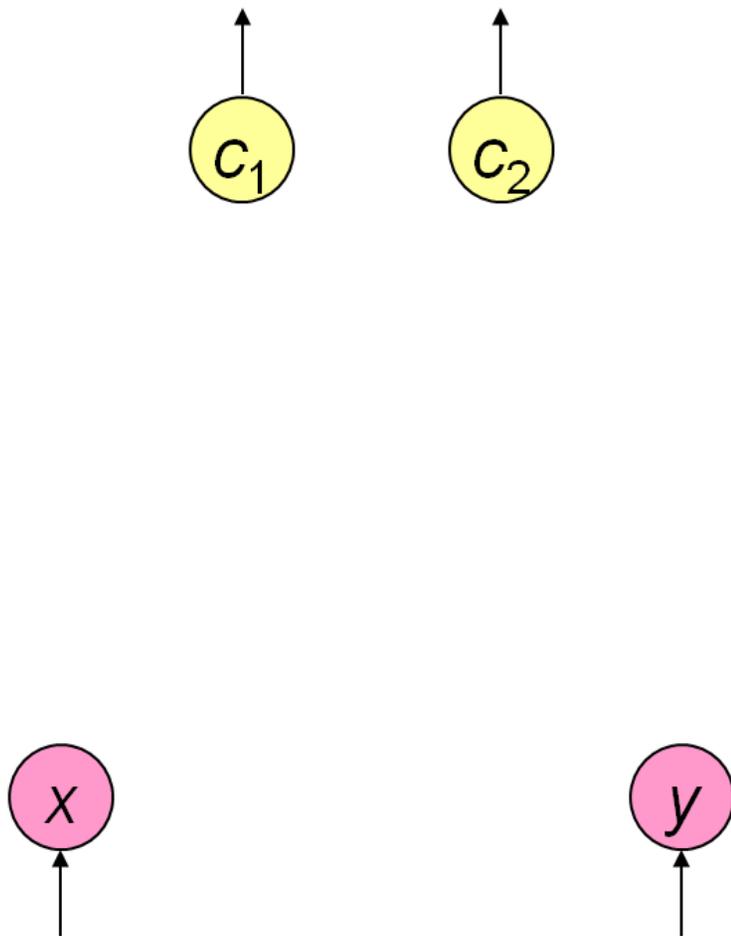
d.h. *large* hat immer

dieselbe Bedeutung in beiden Regeln



# 1. Trainieren: Initialisierung

Spezifiziere anfängliche Fuzzy-Partitionen für alle Eingabevariablen



# 1. Trainieren: Regelbasis

```
for each pattern  $p$  {  
    find antecedent  $A$  s.t.  $A(p)$  is maximal  
    if  $A \notin L$  {  
        add  $A$  to  $L$   
    }  
}  
for each antecedent  $A \in L$  {  
    find best consequent  $C$  for  $A$   
    create rule base candidate  $R = (A, C)$   
    determine performance of  $R$   
    add  $R$  to  $B$   
}  
return one rule base from  $B$ 
```

Fuzzy-Regel-Basen können auch aus Vorwissen, Fuzzy-Cluster-Analyse, Fuzzy-Entscheidungsbäumen, Evolutionären Algorithmen etc. gewonnen werden

# Auswahl einer Regelbasis

Effizienz einer Regel:

$$P_r = \frac{1}{N} \sum_{i=1}^N N(-1)^c R_r(\vec{x}_i)$$

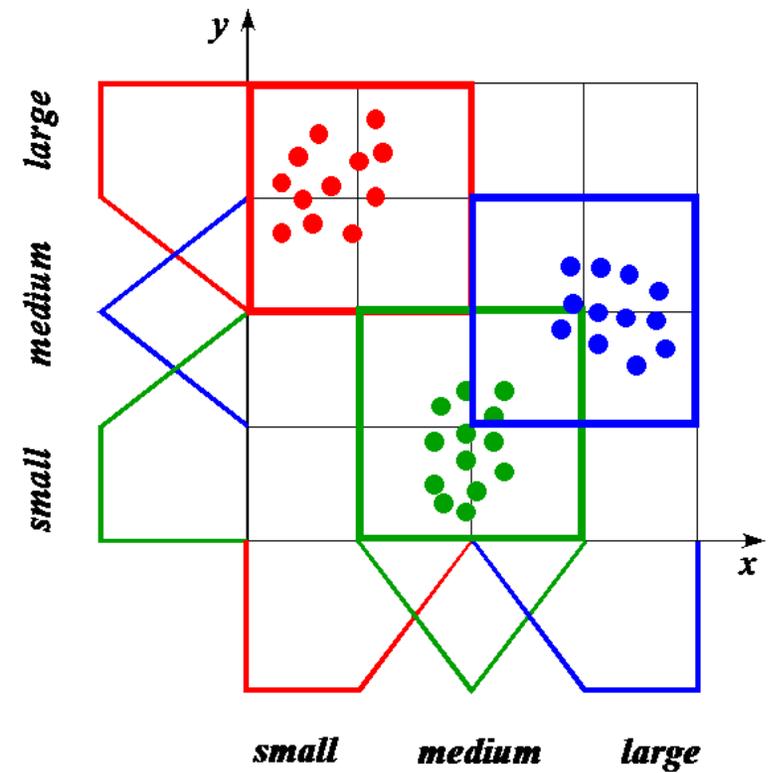
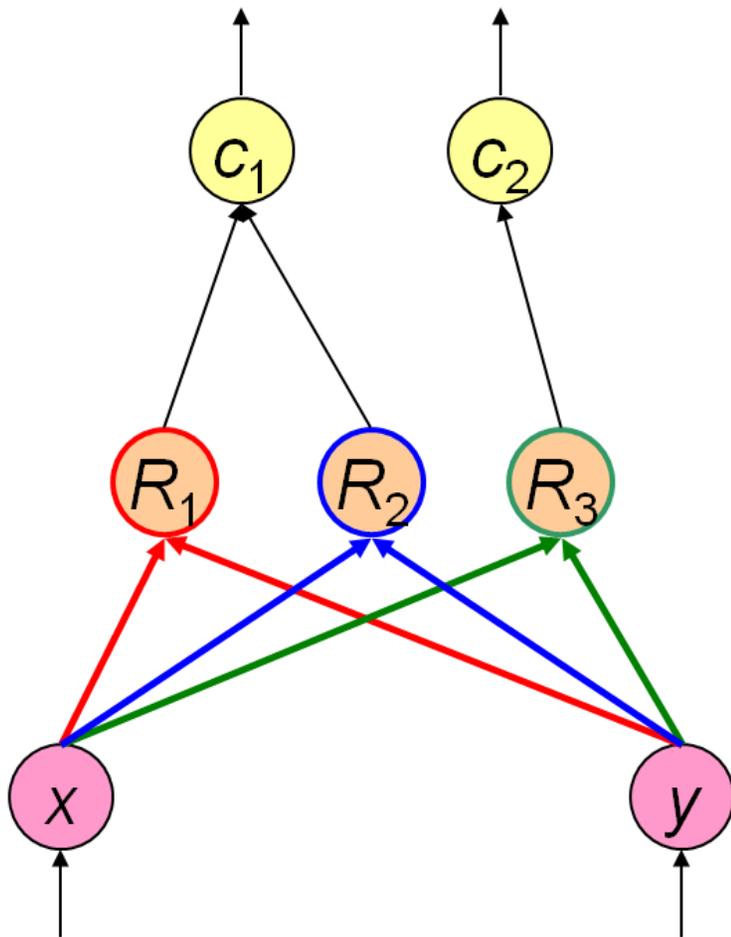
mit

$$c = \begin{cases} 0 & \text{falls } \text{class}(x_i) = \text{con}(R_r), \\ 1 & \text{sonst} \end{cases}$$

- Sortiere Regeln nach Effizienz
- wähle entweder die besten  $r$  Regeln oder die besten  $r/m$  Regeln pro Klasse aus
- $r$  ist entweder gegeben oder wird automatisch so bestimmt, dass alle Muster abgedeckt werden

# Induktion der Regelbasis

NEFCLASS benutzt eine angepasste Wang-Mendel-Prozedur



# Berechnung des Fehlersignals

Fuzzy-Fehler ( $j$ -te Ausgabe):

$$E_j = \text{sgn}(d)(1 - \gamma(d))$$

mit  $d = t_j - o_j$  und

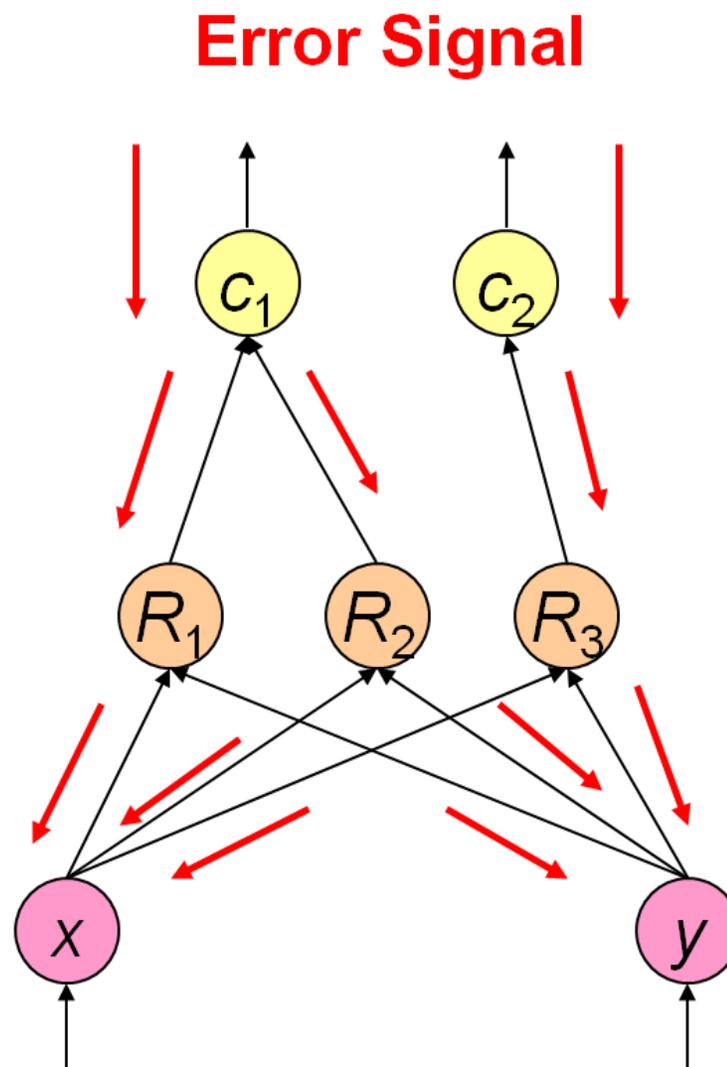
$$\gamma : \mathbb{R} \rightarrow [0, 1], \gamma(d) = \exp - \left( \frac{a \cdot d}{d_{\max}} \right)^2$$

( $t$ : korrekte Ausgabe,  $o$ : aktuelle Ausgabe)

Regel-Fehler:

$$E_r = (\tau_r(1 - \tau_r) + \varepsilon) E_{\text{con}(R_r)}$$

mit  $0 < \varepsilon \ll 1$



### 3. Trainingsschritt: Fuzzy-Mengen

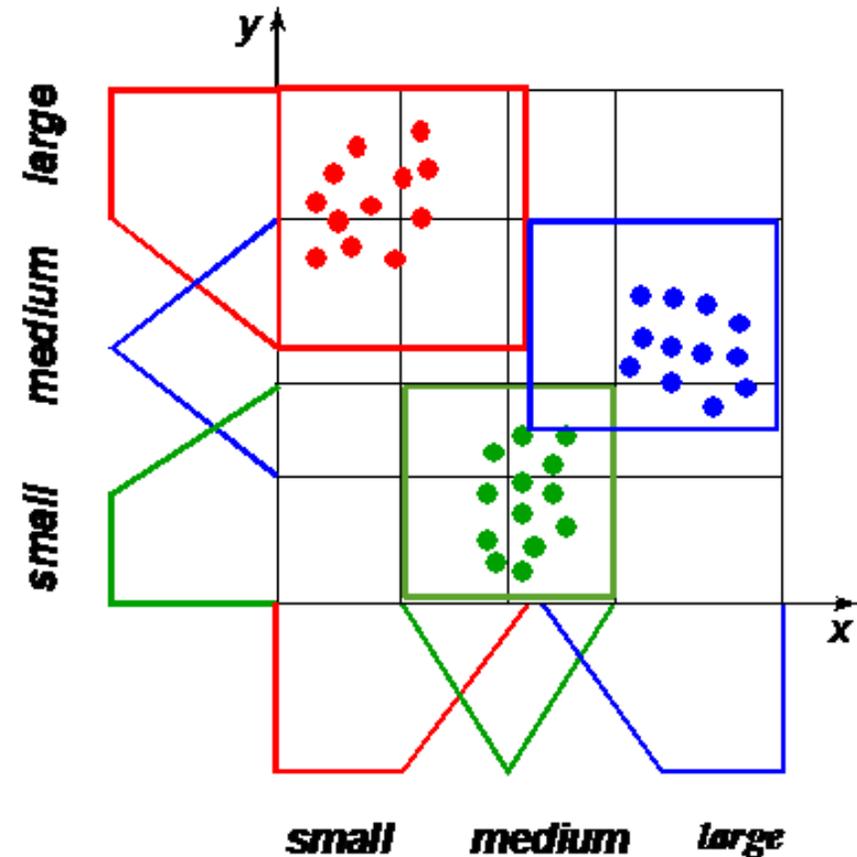
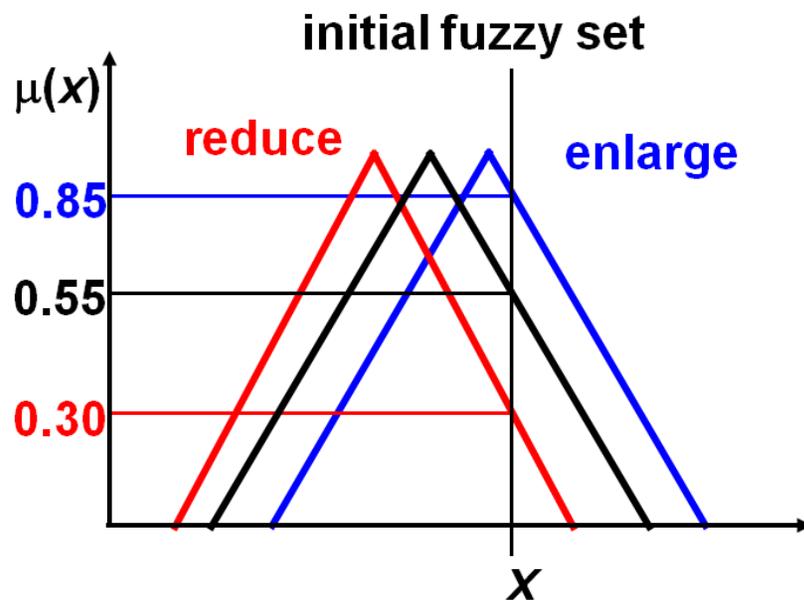
z.B. dreieckige Zugehörigkeitsfunktion

$$\mu_{a,b,c} : \mathbb{R} \rightarrow [0, 1], \quad \mu_{a,b,c}(x) = \begin{cases} \frac{x-a}{b-a} & \text{if } x \in [a, b), \\ \frac{c-x}{c-b} & \text{falls } x \in [b, c], \\ 0 & \text{sonst} \end{cases}$$

Parameteranpassungen für eine Antezedens-Fuzzymenge:

$$f = \begin{cases} \sigma\mu(x) & \text{falls } E < 0, \\ \sigma(1 - \mu(x)) & \text{sonst} \end{cases}$$
$$\Delta b = f \cdot E \cdot (c - a) \operatorname{sgn}(x - b)$$
$$\Delta a = -f \cdot E \cdot (b - a) + \Delta b$$
$$\Delta c = f \cdot E \cdot (c - b) + \Delta b$$

# Trainieren von Fuzzy-Mengen



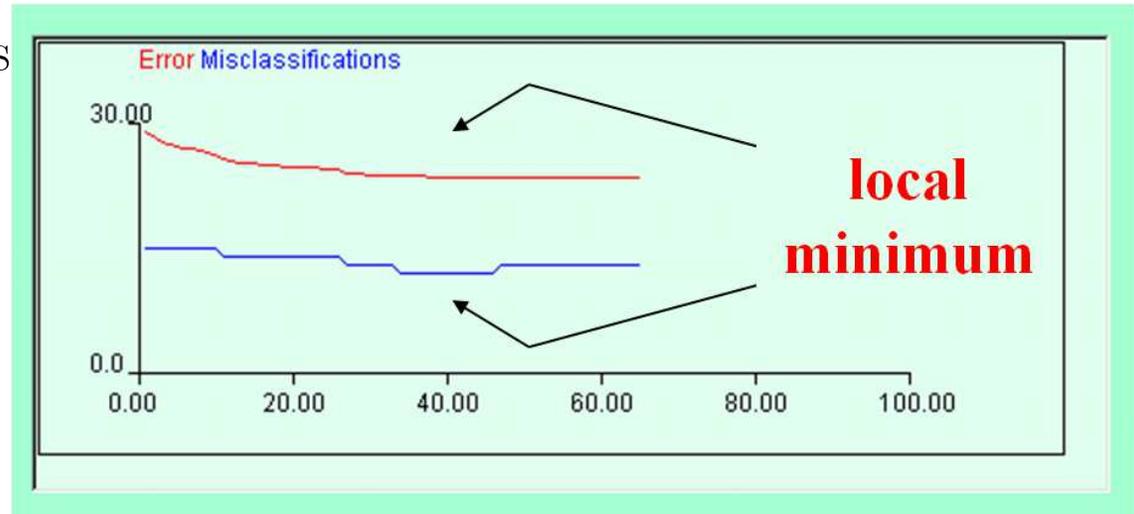
Heuristik: die Fuzzy-Menge wird **von  $x$**  weg (**auf  $x$  zu**) bewegt und ihr *support* wird **reduziert** (**vergrößert**) um den Zugehörigkeitsgrad von  $x$  zu **reduzieren** (**erhöhen**)

# Trainieren von Fuzzy-Mengen

```
do {  
  for each pattern {  
    accumulate parameter updates  
    accumulate error  
  }  
  modify parameters  
} while change in error
```

Varianten:

- Adaptive Lernrate
- Online-/Batch-Lernen
- Optimistisches Lernen ( $n$  Schritte in die Zukunft blickend )



# Einschränkungen beim Trainieren von Fuzzy-Mengen

gültige Parameterwerte

nicht-leere Schnitte

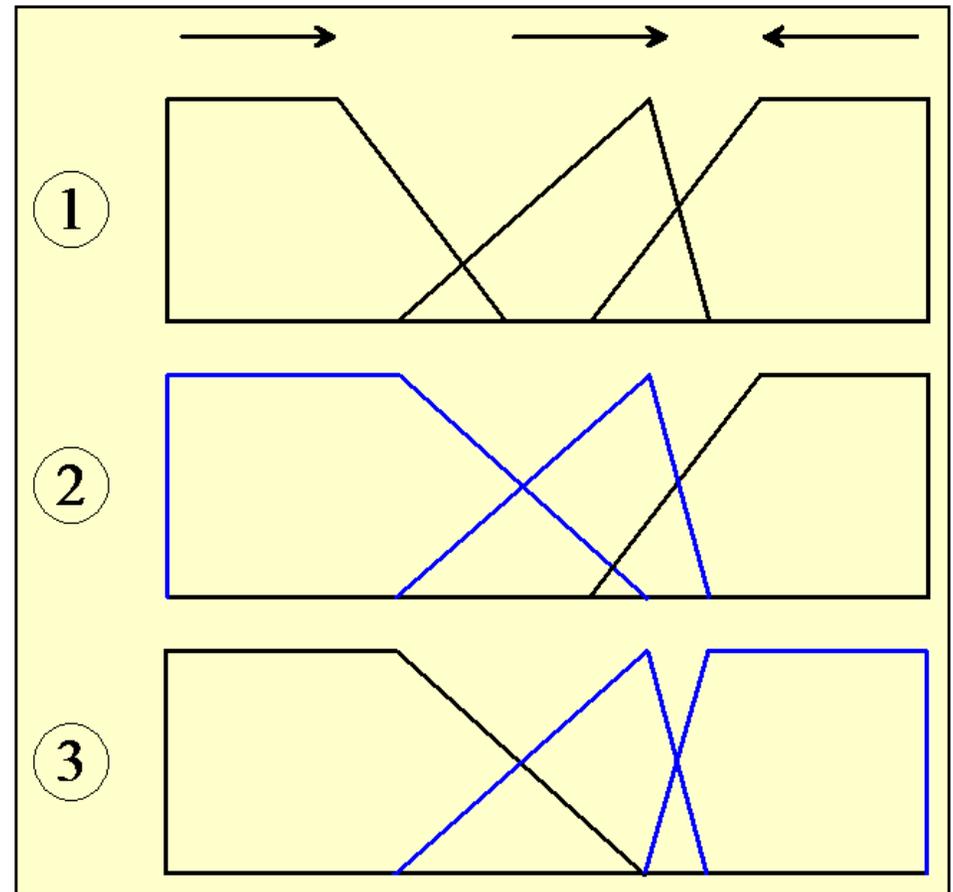
benachbarter Fuzzy-Mengen

Beibehalten relativer Positionen

Erhalt der Symmetrie

Komplette Abdeckung

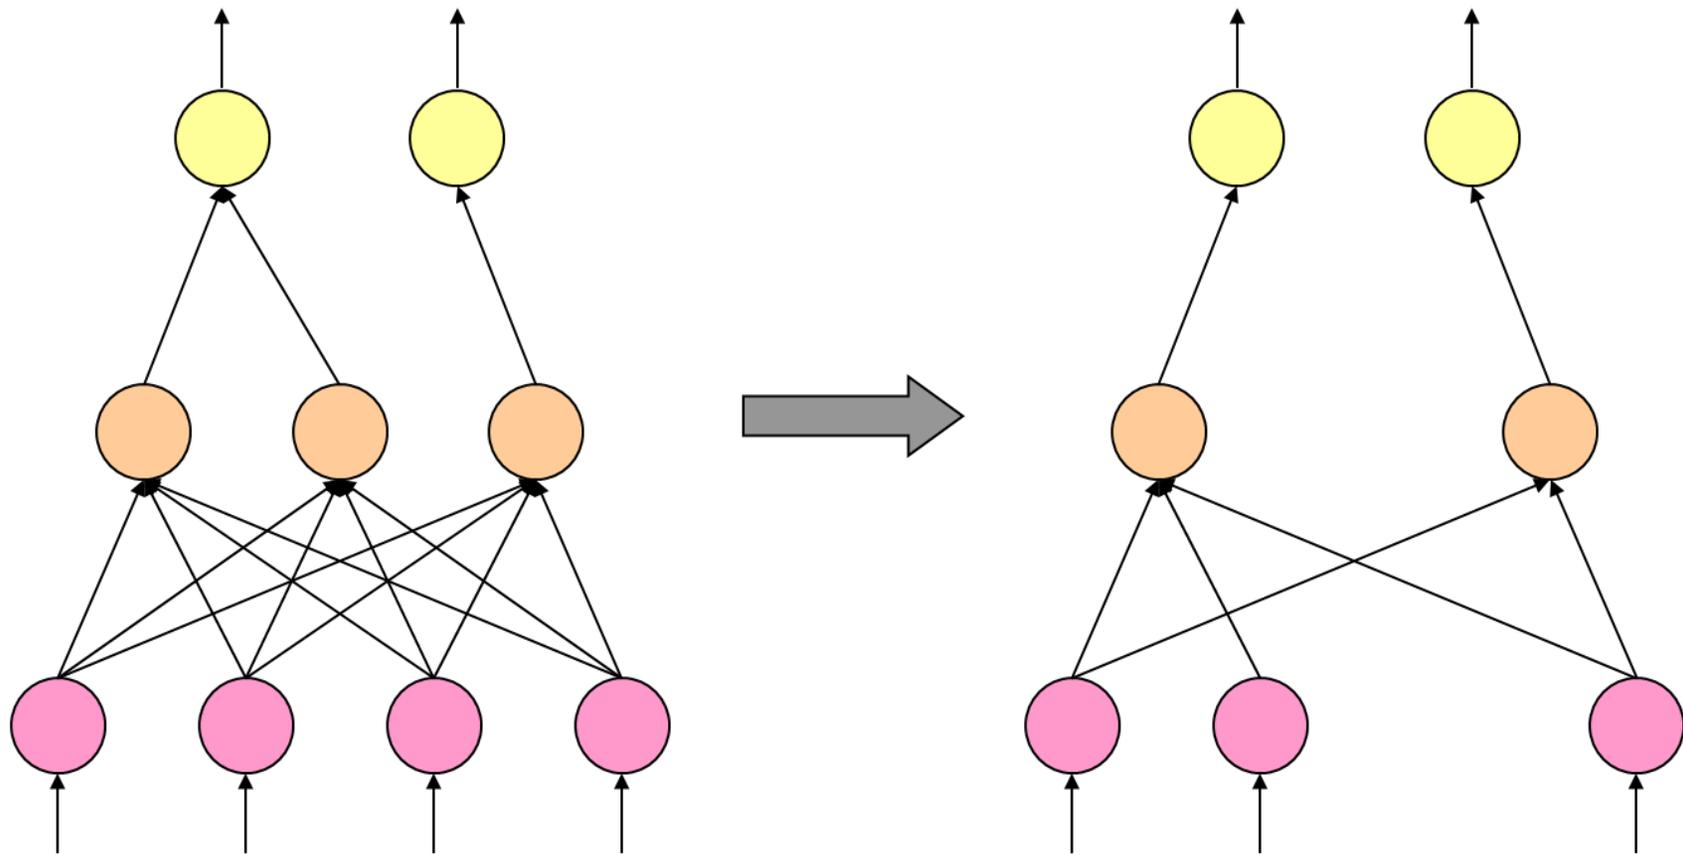
(Zugehörigkeitsgrade für jedes Element summieren sich zu 1)



Correcting a partition after  
modifying the parameters

## 4. Trainingsschritt: Stutzen

Ziel: Entferne Variablen, Regeln und Fuzzy-Mengen, um die Interpretierbarkeit und Generalisierungsfähigkeit zu verbessern



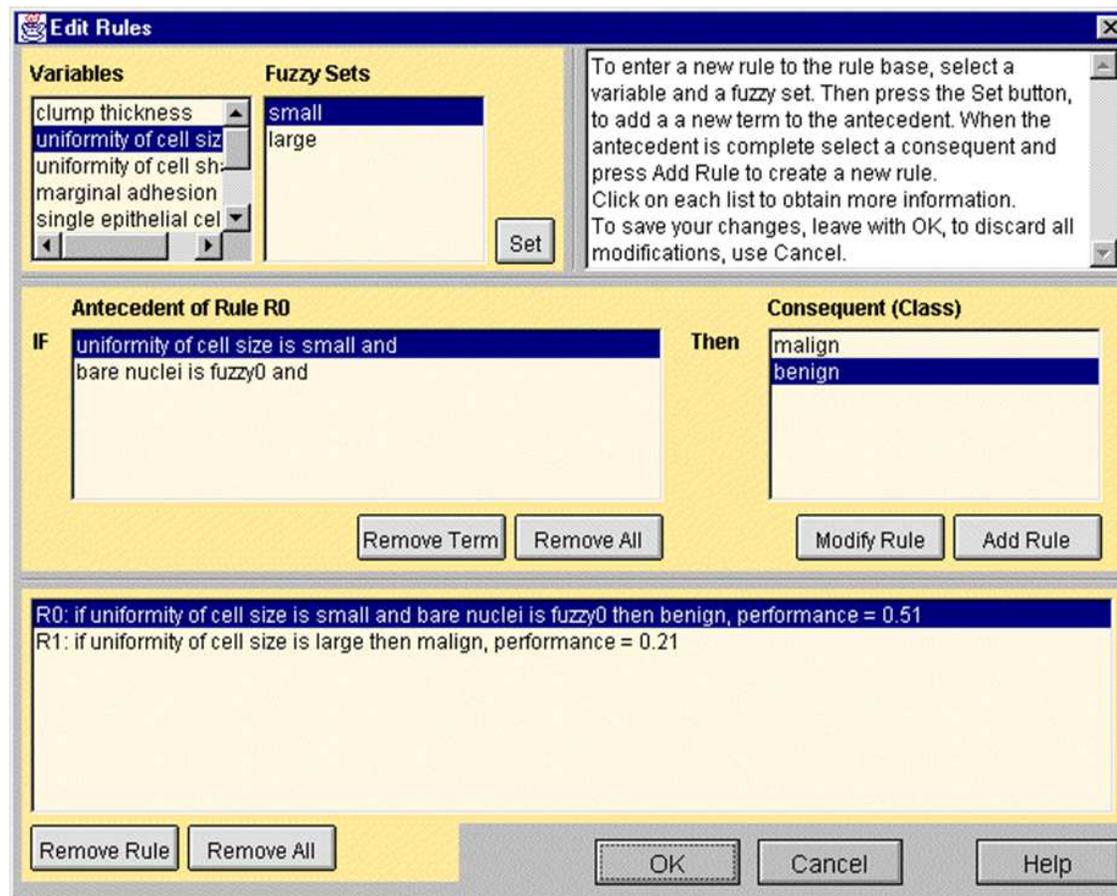
```
do {  
  select pruning method  
  do {  
    execute pruning step  
    train fuzzy sets  
    if no improvement {  
      undo step  
    }  
  } while there is improvement  
} while there is further method
```

1. Entferne Variablen (Korrelationen, Information Gain, etc.)
2. Entferne Regeln (Effizienz einer Regel)
3. Entferne Terme (Erfüllungsgrad einer Regel)
4. Entferne Fuzzy-Mengen

# WBC- Ergebnisse: Fuzzy-Regeln

$R_1$ : if uniformity of cell size is *small* and bare nuclei is fuzzy0 then *benign*

$R_2$ : if uniformity of cell size is *large* then *malignant*



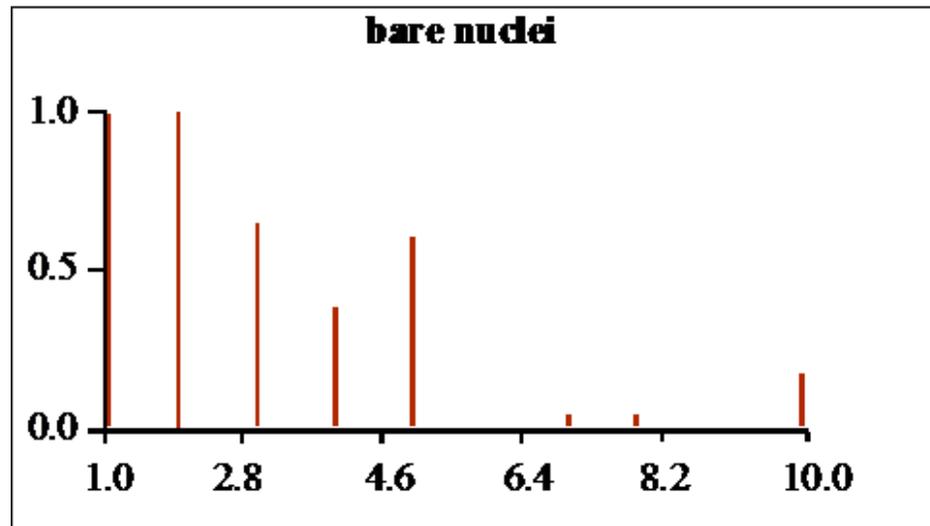
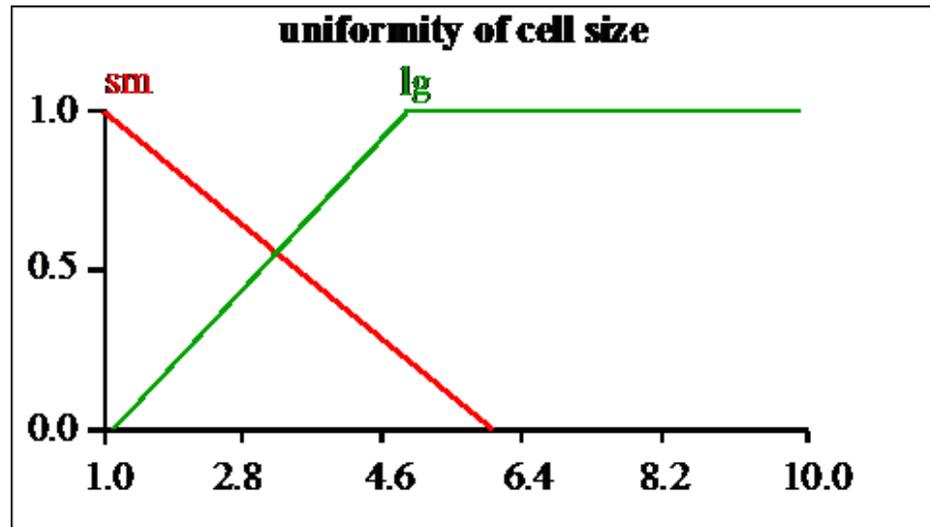
# WBC-Ergebnisse: Klassifikation

	vorhergesagte Klasse		
	bösartig	gutartig	$\Sigma$
bösartig	228 (32.62%)	13 (1.86%)	241 (34.99%)
gutartig	15 (2.15%)	443 (63.38%)	458 (65.01%)
$\Sigma$	243 (34.76)	456 (65.24)	699 (100.00%)

Geschätzte Vorhersageleistung auf unbekanntem Daten (Kreuzvalidierung):

NEFCLASS-J:	95.42%	NEFCLASS-J (numerisch):	94.14%
Discriminant Analysis:	96.05%	Multilayer Perceptron:	94.82%
C 4.5:	95.10%	C 4.5 Rules:	95.40%

# WBC-Ergebnisse: Fuzzy-Mengen



# NEFCLASS-J

The screenshot displays the NEFCLASS-J software interface with several windows open:

- Fuzzy Set Learning:** A graph showing 'Error Misclassifications' over time. The error starts at 49.00 and decreases to approximately 10.00 by 180.00 iterations.
- NEFCLASS (Main Window):** Shows 'status' as 'ready', 'classifier' as '5 rules, trained', and 'training data' as 'Iris\_new.dat'.
- Fuzzy Sets:** A graph showing three fuzzy sets: 'sm' (small), 'md' (medium), and 'lg' (large). The x-axis ranges from 1.0 to 7.0, and the y-axis from 0.0 to 1.0.
- List of Variables:** Lists 'sepal length', 'sepal width', 'petal length', and 'petal width'.
- Rule Learning:** A text window reporting: '20 possible rules found. Now determine the optimal combination. Selection of consequents is complete. Writing the rules to the log file, please wait. Best rule learning: selecting the best 5 rules. Best rules selected, trimming the rule base. Rule base with 5 rules created. WARNING: This rule base covers only 94% of all training patterns but this may improve during fuzzy set learning. Performance on training data (100.0% of all cases): 150 patterns, 15 misclassifications (error = 26.45762)'.
- Edit Rules:** A window for editing rules. It shows 'Variables' (sepal length, sepal width, petal length, petal width) and 'Fuzzy Sets' (small, medium, large). The 'Antecedent of Rule R0' is 'sepal length is small and sepal width is medium and petal length is small and petal width is small'. The 'Consequent (Class)' is 'Iris Setosa, Iris Versicolor, Iris Virginica'.
- About:** A window with the NEFCLASS-J logo and text: 'NEFCLASS-J Version 1.0 Programming and GUI Design Ulrike Nauck NEFCLASS Model and Learning Algorithms Dr. Dettlef Nauck (c) Ulrike Nauck, Braunschweig, 1998'.

## Heutiges Verfahren

Oberflächenkontrolle:  
manuell durchgeführt

erfahrener Arbeiter bearbeitet  
Oberfläche mit Schleifstein

Experten klassifizieren Abweichungen  
durch sprachliche Beschreibungen

umständlich, subjektiv,  
fehleranfällig, zeitaufwendig

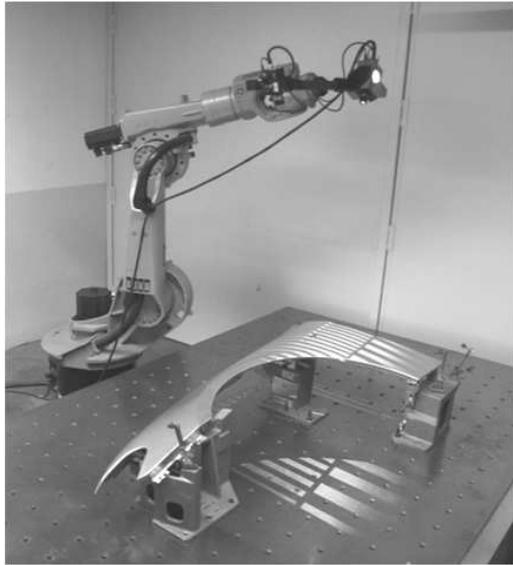
## vorgeschlagener Ansatz:

Digitalisierung der Oberfläche mit optischen Mess-Systemen

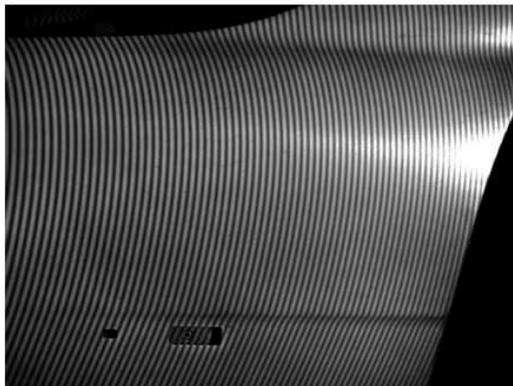
Charakterisierung der Formabweichungen durch mathematische Eigenschaften (nahe der subjektiven Merkmale)



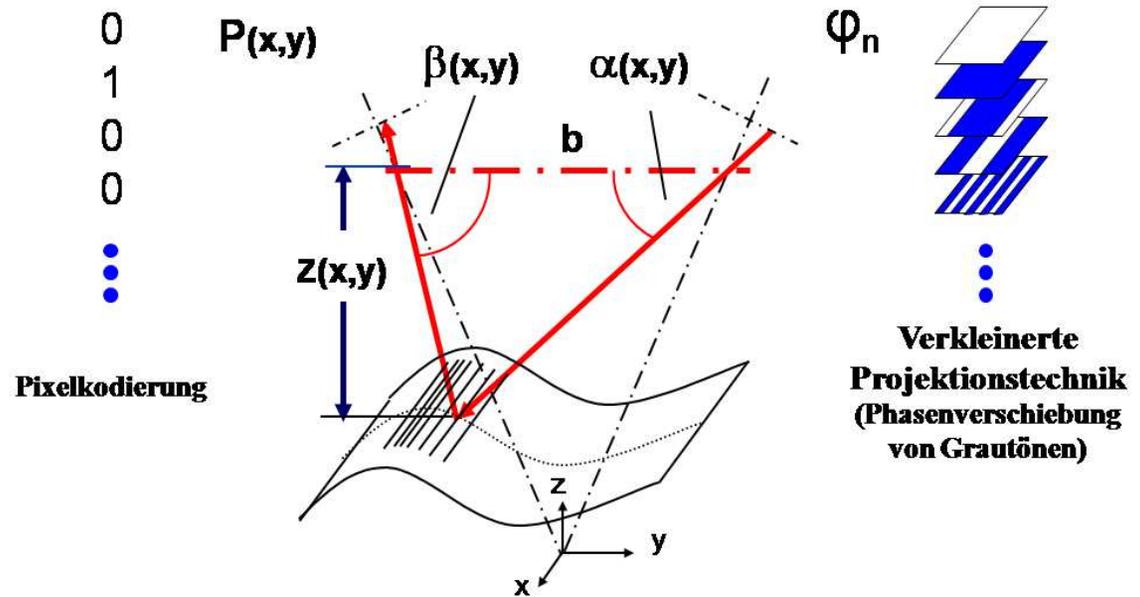
# Topometrisches 3D Mess-System



breuckmann 

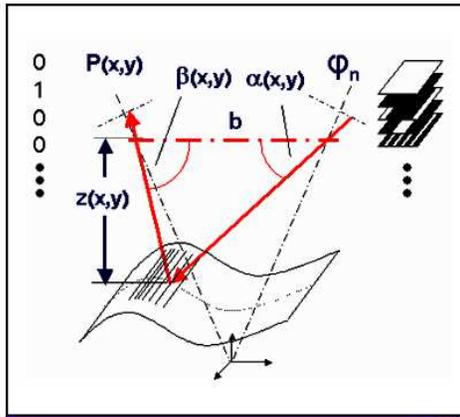


## Triangulation und Gitterprojektion

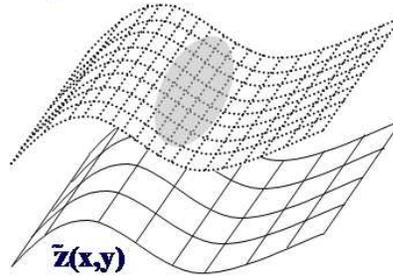


- hohe Punktdichte
- schnelle Datenansammlung
- genaue Messung
- kontakt- und harmlos

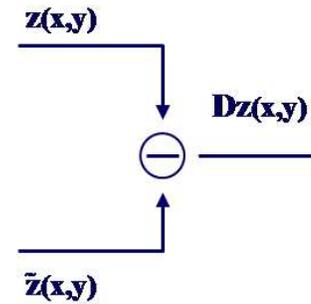
# Datenverarbeitung



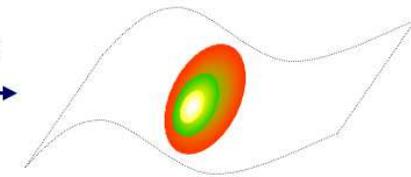
• Annäherung durch  
Polynomiale Oberfläche



• Differenz



• Farbkodierte  
• Darstellung



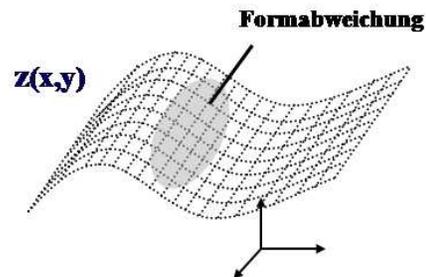
3-D-Daten-  
aufnahme

Nachverarbeitung

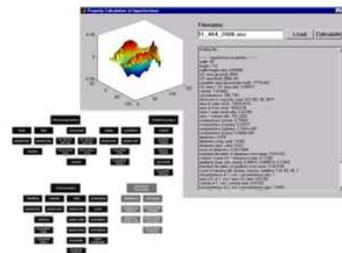
Erkennung von  
Abweichungen

Merkmalsanalyse

• 3-D-Punktwolke



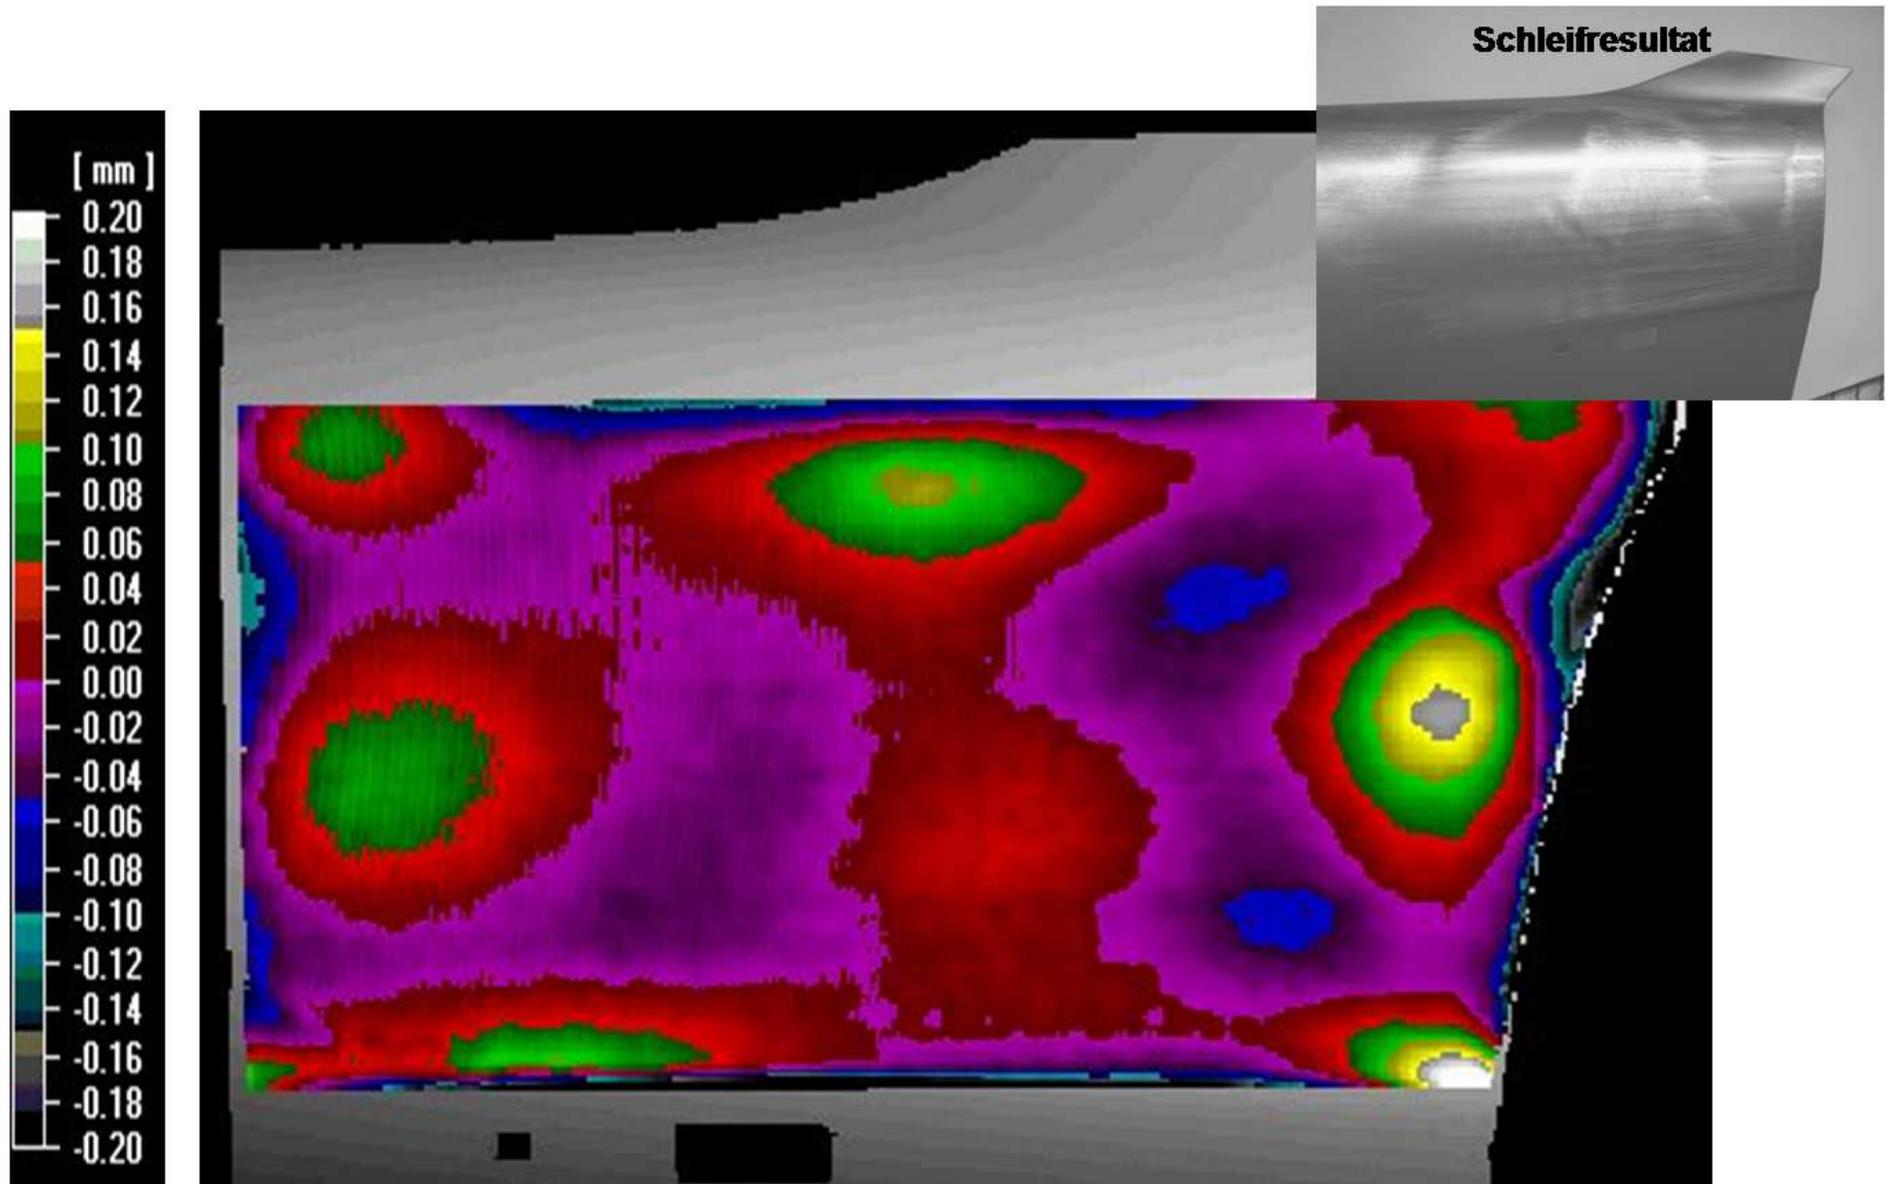
• Merkmalsberechnung



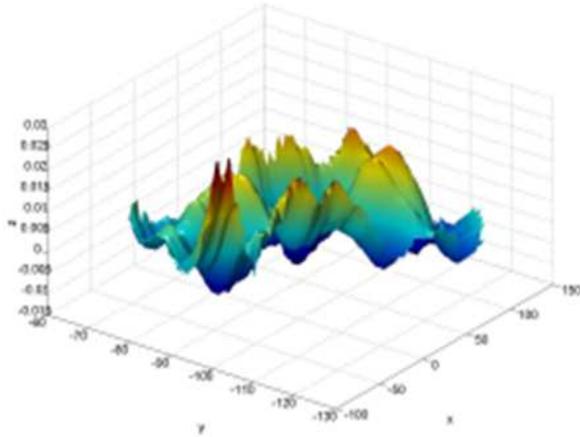
• Klassifikation (Data-Mining)



# Farbkodierte Darstellung

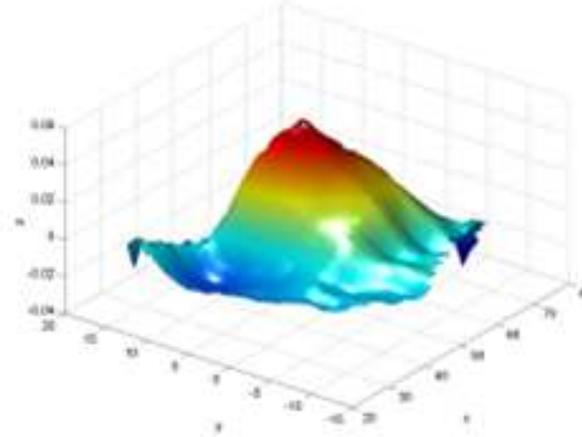


# 3D-Darstellung lokaler Oberflächendefekte



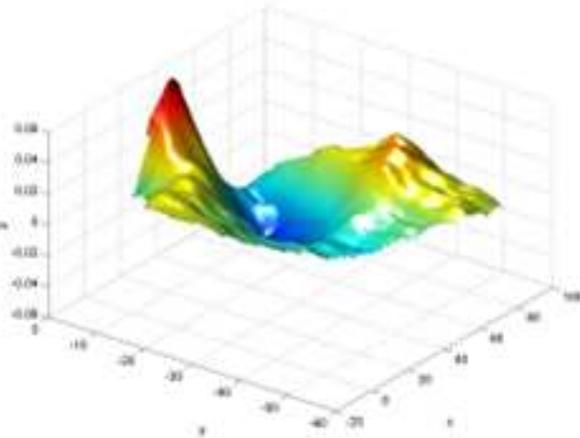
**unebene Oberfläche**

mehrere Einfallstellen in Serie/benachbart



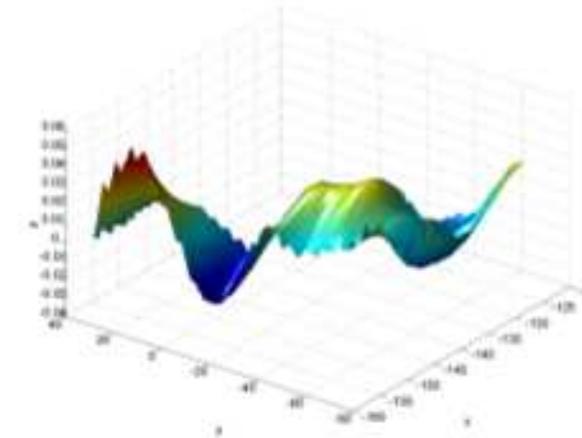
**Walzenmarkierung**

lokale Glättung der Oberfläche



**Einfallstelle**

leichte flach basierte Senke einwärts



**Wellplatte**

mehrere schwerere Faltungen in Serie

# Charakteristik der Daten

9 Meisterstücke mit insgesamt 99 Defekten analysiert

Für jeden Defekt, 42 Merkmale berechnet

Typen sind eher unbalanciert

Seltene Klassen verworfen

Einige extrem korrelierte Merkmale verworfen (31 übrig)

Rangfolge der 31 Merkmale nach Wichtigkeit

Geschichtete 4-fache Kreuzvalidierung fürs Experiment

## Regelbasis für NEFCLASS:

### Rule base

- Rule 1: IF (max\_distance\_to\_cog IS fun 2 AND min\_extrema IS fun 1 AND max\_extrema IS fun 1) THEN type IS press\_mark
- Rule 2: IF (max\_distance\_to\_cog IS fun 2 AND all\_extrema IS fun 1 AND max\_extrema IS fun 2) THEN type IS sink\_mark
- Rule 3: IF (max\_distance\_to\_cog IS fun 3 AND min\_extrema IS fun 2 AND max\_extrema IS fun 2) THEN type IS uneven\_surface
- Rule 4: IF (max\_distance\_to\_cog IS fun 2 AND min\_extrema IS fun 2 AND max\_extrema IS fun 2) THEN type IS uneven\_surface
- Rule 5: IF (max\_distance\_to\_cog IS fun 2 AND all\_extrema IS fun 1 AND min\_extrema IS fun 2) THEN type IS press\_mark
- Rule 6: IF (max\_distance\_to\_cog IS fun 3 AND all\_extrema IS fun 2 AND max\_extrema IS fun 3) THEN type IS uneven\_surface
- Rule 7: IF (max\_distance\_to\_cog IS fun 3 AND min\_extrema IS fun 3) THEN type IS uneven\_surface

## Klassifikationsgenauigkeit:

	NBC	DTree	NN	NEFCLASS	DC
Trainingsmenge	89.0%	94.7%	90%	81.6%	46.8%
Testmenge	75.6%	75.6%	85.5%	79.9%	46.8%

Neuro-Fuzzy-Systeme können nützlich zur Wissensentdeckung sein

Interpretierbarkeit ermöglicht die Plausibilitätskontrolle und erhöht die Akzeptanz

NFS nutzen Toleranzen aus, um zu beinahe optimalen Lösungen zu kommen

NFS-Lernalgorithmen müssen mit Einschränkungen umgehen können, um die Semantik des ursprünglichen Modells nicht zu verletzen

Keine automatische Modellerstellung  $\Rightarrow$  Benutzer muss mit dem Werkzeug **umgehen**

Einfache Lerntechniken unterstützen die explorative Datenanalyse.