INF FAKULTÄT FÜR INFORMATIK

Intelligente Systeme

Computational Intelligence

Prof. Dr. R. Kruse C. Braune C. Moewes

{kruse,cbraune,cmoewes}@iws.cs.uni-magdeburg.de

Institut für Wissens- und Sprachverarbeitung
Fakultät für Informatik
Otto-von-Guericke Universität Magdeburg

Übersicht

Computational Intelligence ist charakterisiert durch:

- meist modellfreie Ansätze,
- kein explizites Modell notwendig
- z.B. Lösen von Differentialgleichungen
- Approximation statt exakte Lösung (nicht immer ausreichend!)
- schnelleres Finden einer brauchbaren Lösung
- u.U. auch ohne tiefgehende Problemanalyse

CI-Forschungsthemen

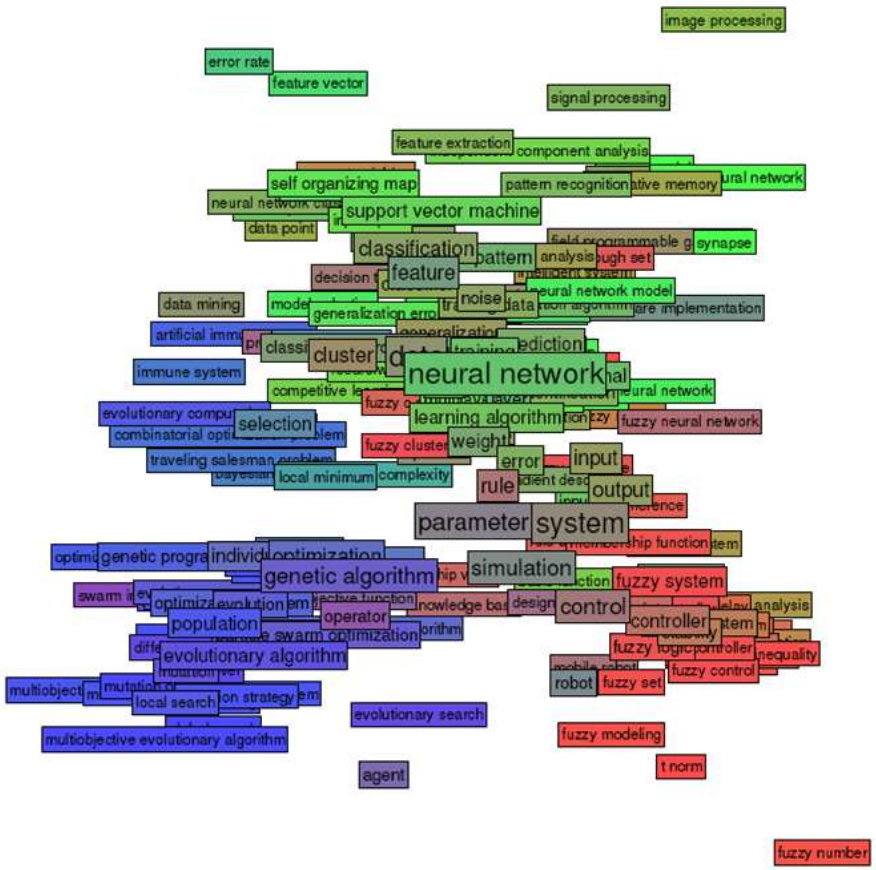

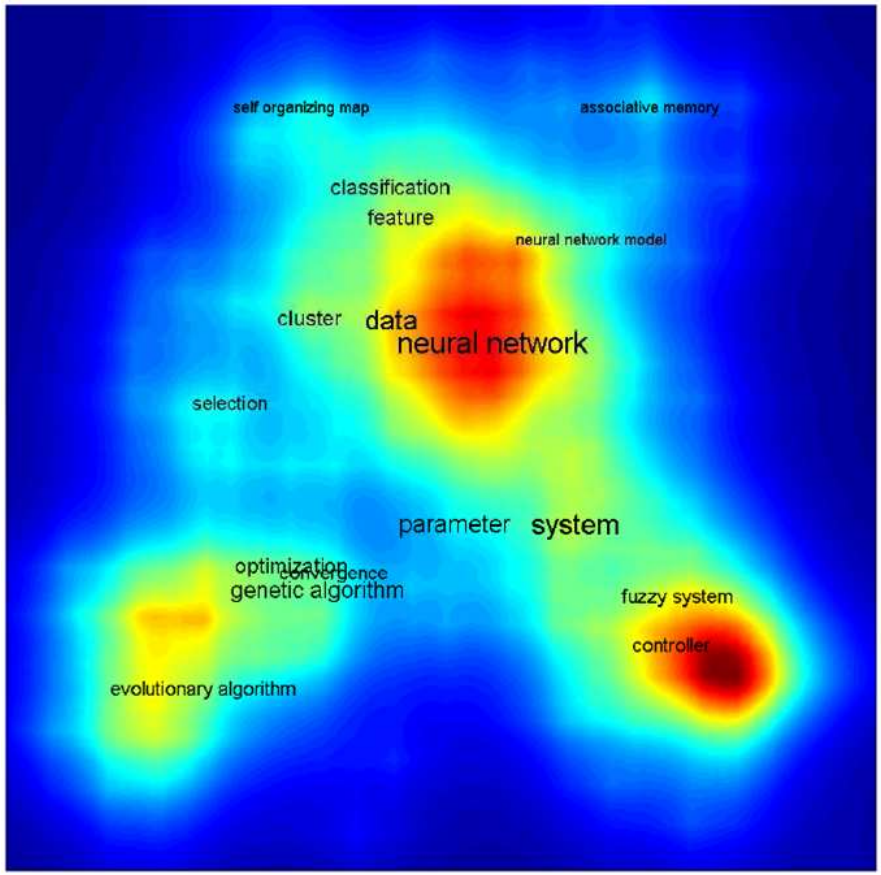

CI: Technologien und Anwendungen

Kerntechnologien

Neuronale Netze (NN)
Fuzzy-Logik (FL)
Probabilistisches Schließen (PR)
Evolutionäre Algorithmen (EA) und weitere Metaheuristiken
Hybride Systeme

Verwandte Technologien

Fallbasiertes Schließen (CBR)
Regelbasierte Expertensysteme (RBR)
Maschinelles Lernen (z.B. Induktionsbäume)
Bayessche Belief-Netze (BBN)

Anwendungen

Klassifikation

- Überwachung/ Anomalieerkennung
- Diagnose
- Prognose
- Konfiguration/Initialisierung

Vorhersage

- Qualitätskontrolle
- Alterungsprozessmodellierung

Terminplanung

- Zeit-/Ressourcenzuweisung

Regelung

- Maschinen-/Prozesskontrolle
- Prozessinitialisierung
- Überwachungskontrolle

Automatische Entscheidung

- Kosten-/Risikoanalyse
- Einkommensoptimierung

Übersicht

Computational Intelligence

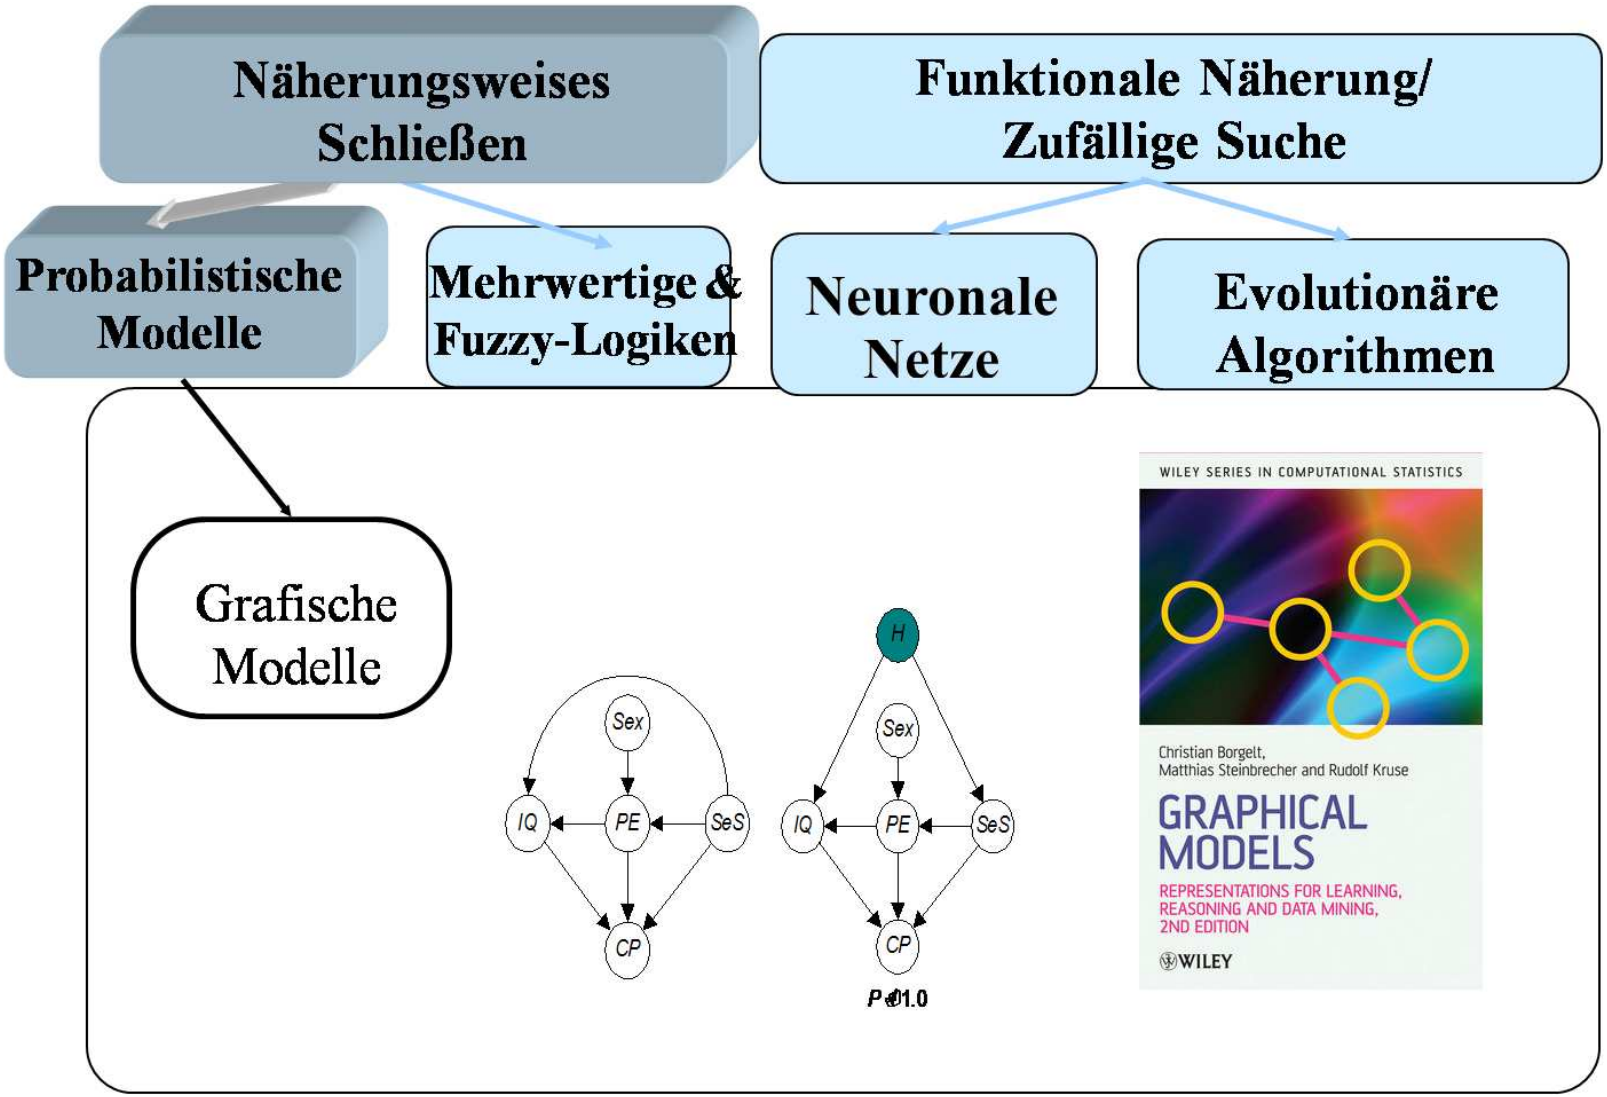

Hybride Neuro-Fuzzy-Systeme

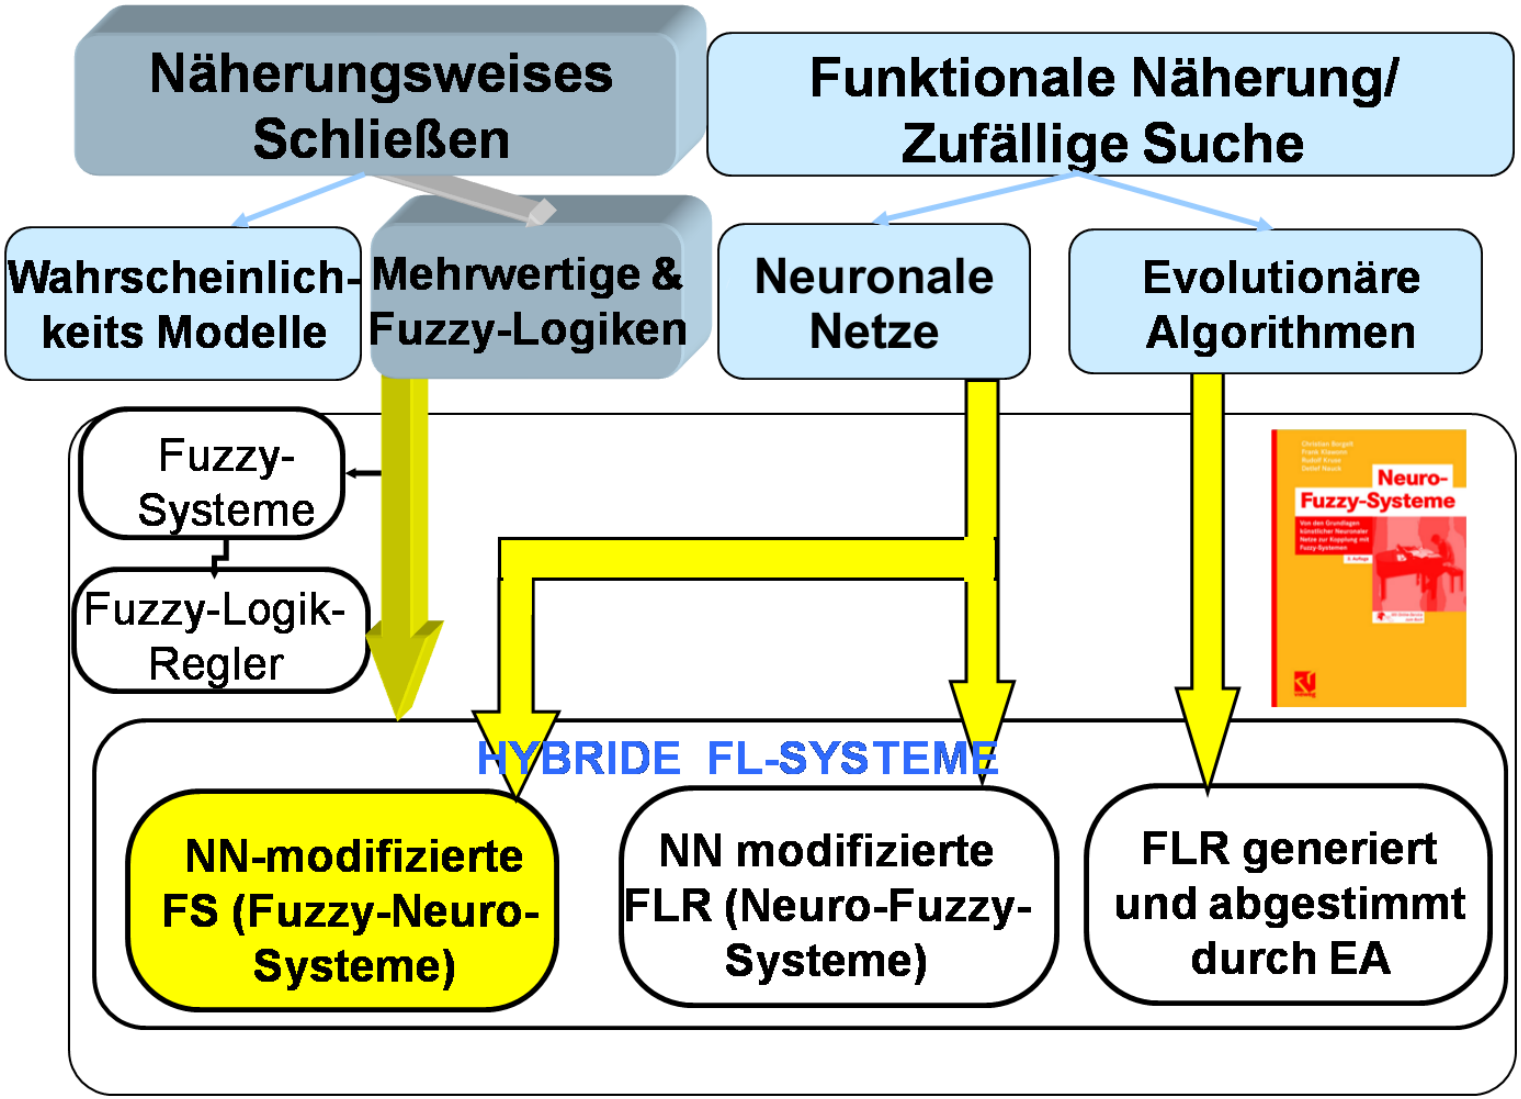

CI: Anwendungen

Haushaltsgeräte
- Bevorzugte Serviceverträge (Stat.)
- Call-Center-Support (CBR)

Kapitalservice
- Kreditwürdigkeitsbewertung (Fusion/FL/CBR)

Finanzversicherungen
- Bevorzugte Kunden (Stat./NN)

Plastik
- Automatische Farbanpassung (CBR)

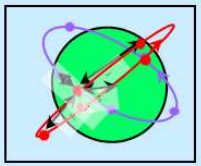

Föderierte Systeme
- Terminwartung von Satelliten-konstellationen (GA)

Schifffahrt
- Schiffmanagementsystme (AI/GA)

Medizinische Systeme
- Automatische Analyse von MRT (FL)
- Reverse Engineering von Picker (FL)
- Finite-Element-Analyse (FL)
- Analye von Röntgenfehlern (CBR)

Flugzeugmotoren
- Zentrum für Ferndiagnosen (CBR)
- Kundenanfragecenter (CBR)
- Ausreißererkennung (FL/Stat.)
- Wartungsberater (NN/FL)
- Sensorfusion (FL)

Transportsysteme
- Erfassung von Transport-DB (CBR)
- Prototyp. Zugführerkontrolle (FL/GA)
- Prototyp. Trendanalyse (Stat.)
- Eingebettete/Ferndiagnose (BBN)

Stromerzeugung
- Fernausreißererkennung (Stat.)
- Eingebettete/Ferndiagnose (BBN)
- Call-Center-Problem/Lösung (CBR)

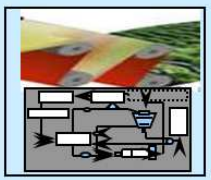

Industriesysteme
- Vorhersage eines Abbruchs der Papierbahn (NN/Stat./Induction)
- Rührkontrolle von Zement (FL/GA)

CI: Grundlage und verwandte Technologien

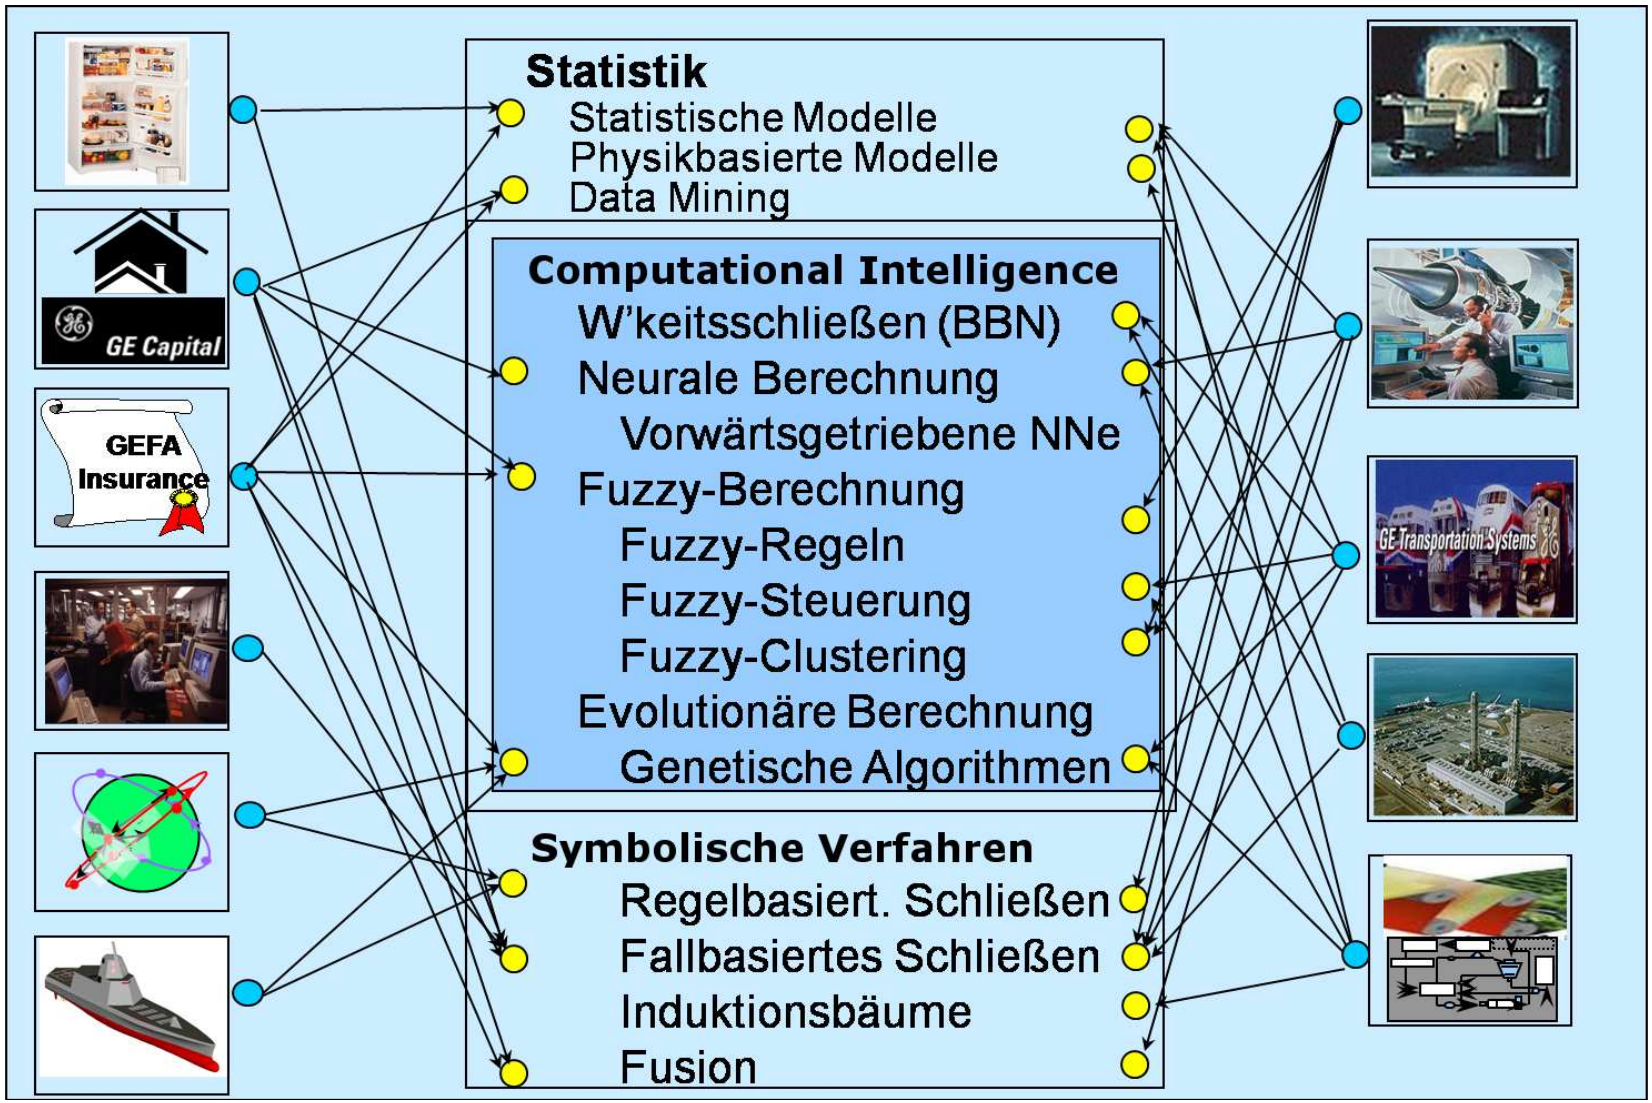

Übersicht

Beispiel: DAX-Prognosen

Datenbasis: Zeitreihe von 1986–1997

DAX	Composite-DAX
Deutsche 3-Monate-Zinsrate	Return Germany
Deutscher Morgan-Stanley-Index	Industrie-Index des Dow Jones
DM / US-$	US Schatzanweisungen
Goldpreis	Japanischer Nikkei-Index
Europäischer Morgan-Stanley-Index	Verhältnis von Preis und Ertrag

Fuzzy-Regeln in der Finanzwelt

Entwicklungsregel
- WENN DAX = fallend UND US-$ = fallend
- DANN DAX-Voraussage = fallend
- MIT hoher Gewissheit

Wendepunktregel
- WENN DAX = fallend UND US-$ = steigend
- DANN DAX-Voraussage = steigend
- MIT niedriger Gewissheit

Verzögerungsregel
- WENN DAX = stabil UND US-$ = fallend
- DANN DAX-Voraussage = fallend
- MIT sehr hoher Gewissheit

generell
- WENN x_1 ist μ_1 UND x_2 ist μ_2 UND ... UND x_n ist μ_n
- DANN $y = \eta$
- MIT Gewicht k

Neuro-Fuzzy-Architektur

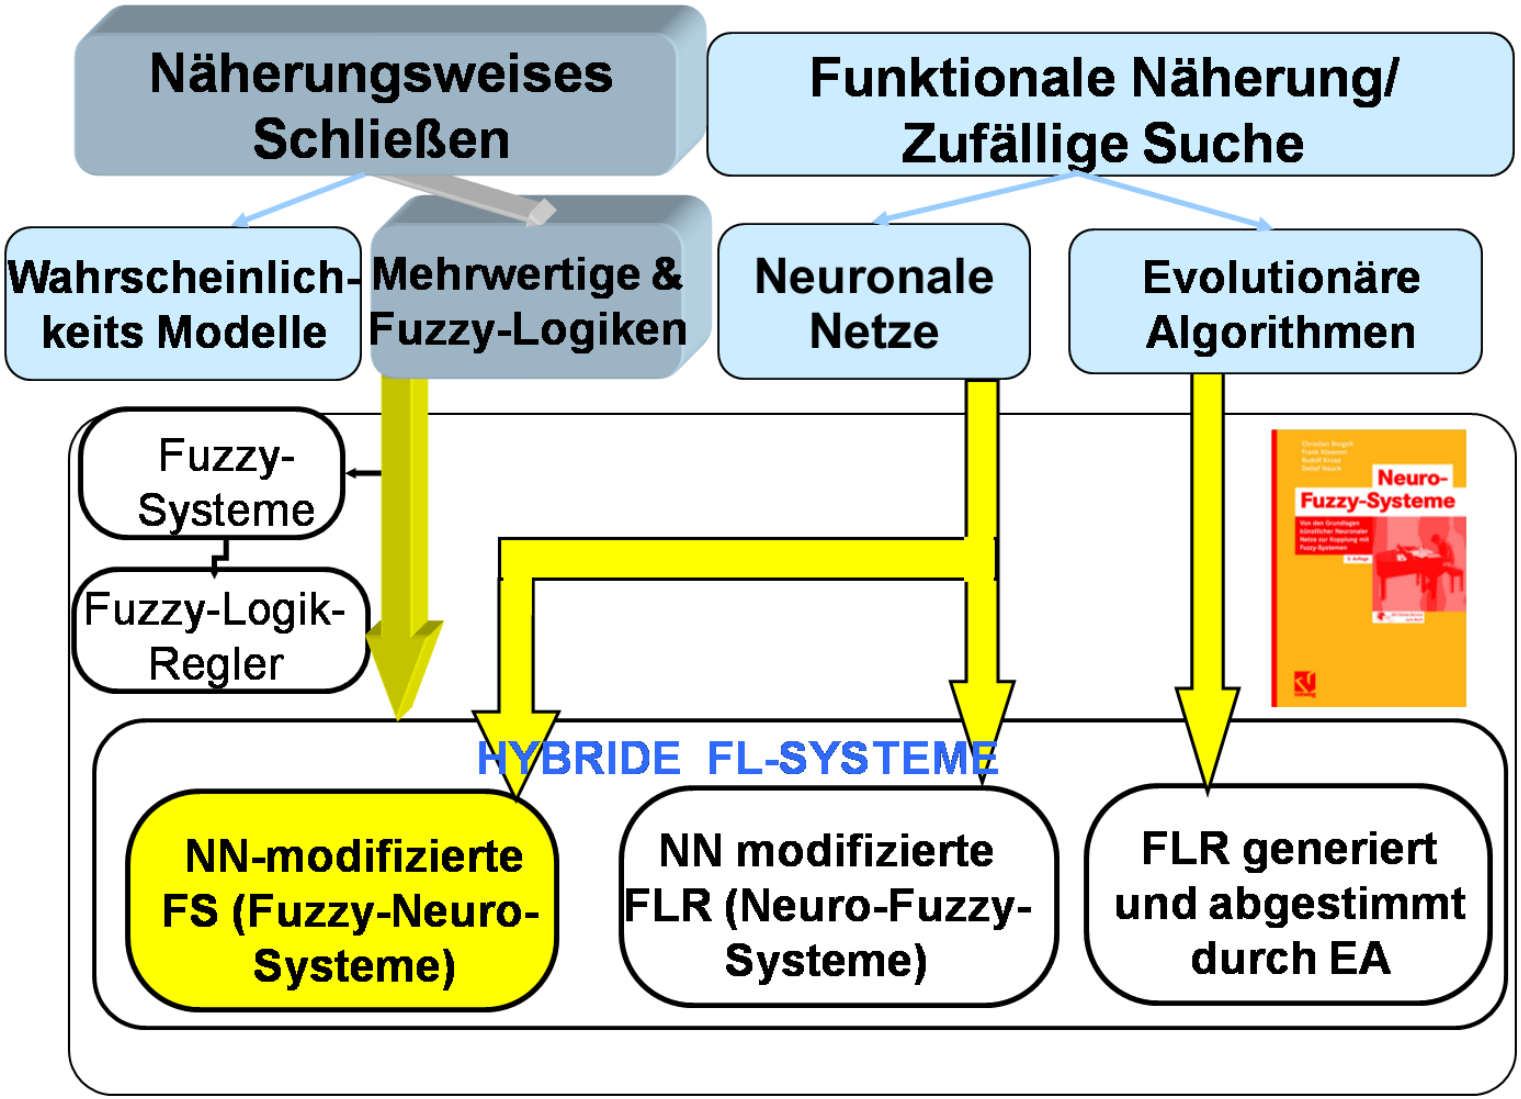

Neuro-Fuzzy-Architektur

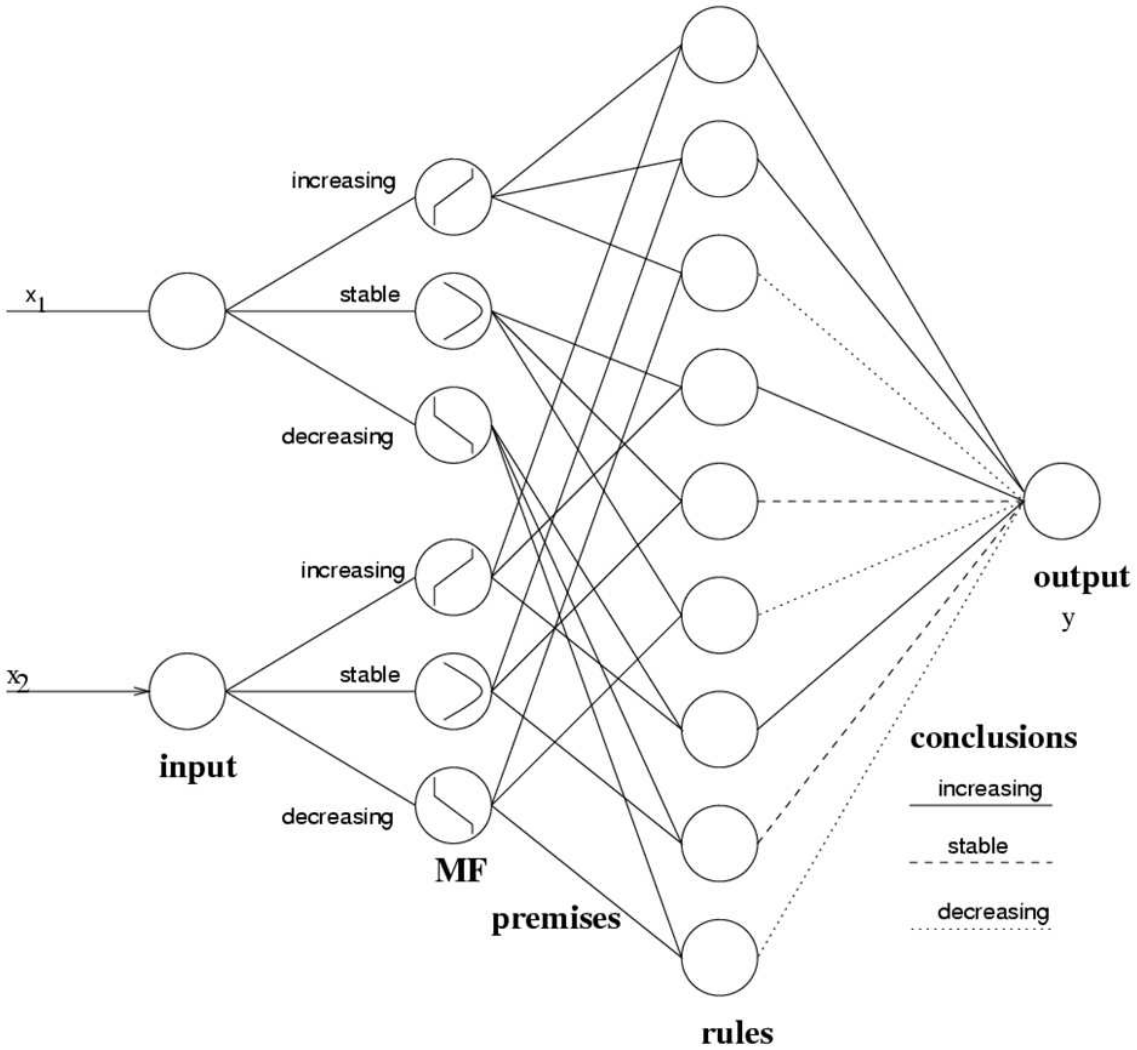

Return-on-Investment-Kurven

verschiedene Modelle

Validierungsdaten: 01. März 1994 bis April 1997

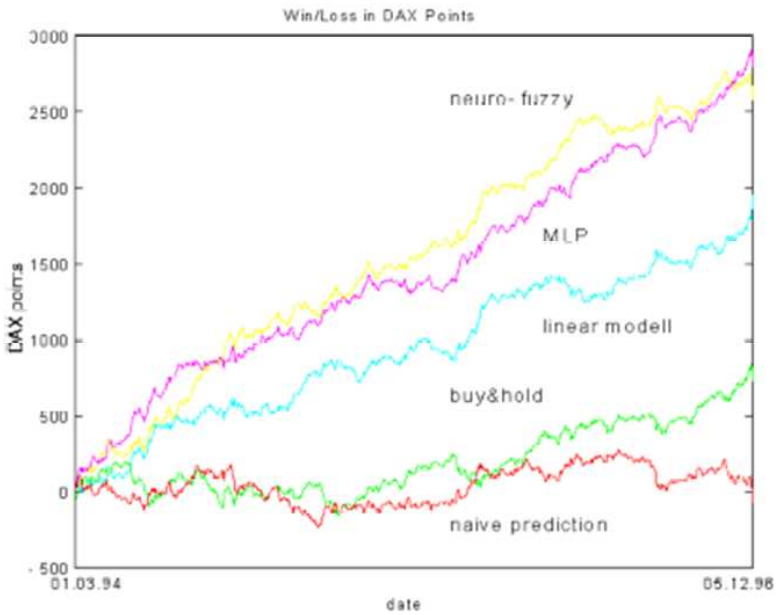

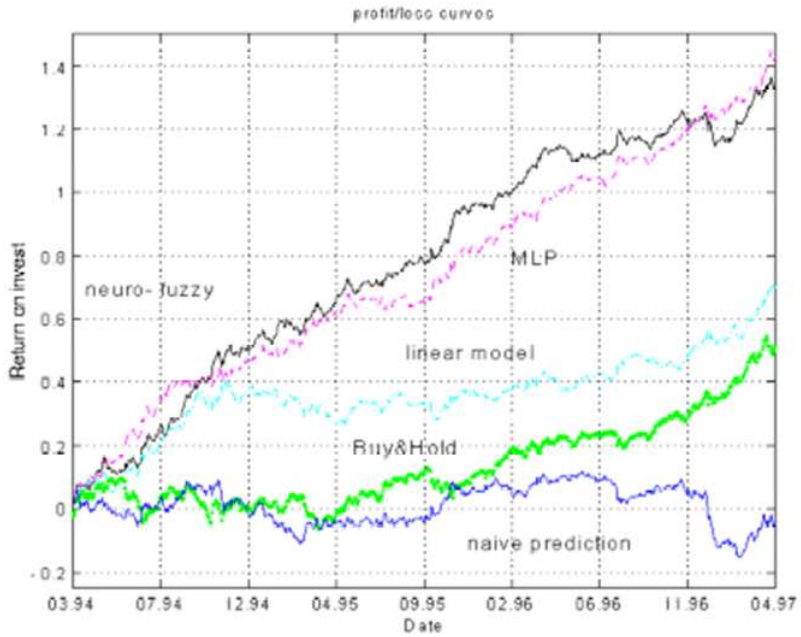

NEFCLASS-J

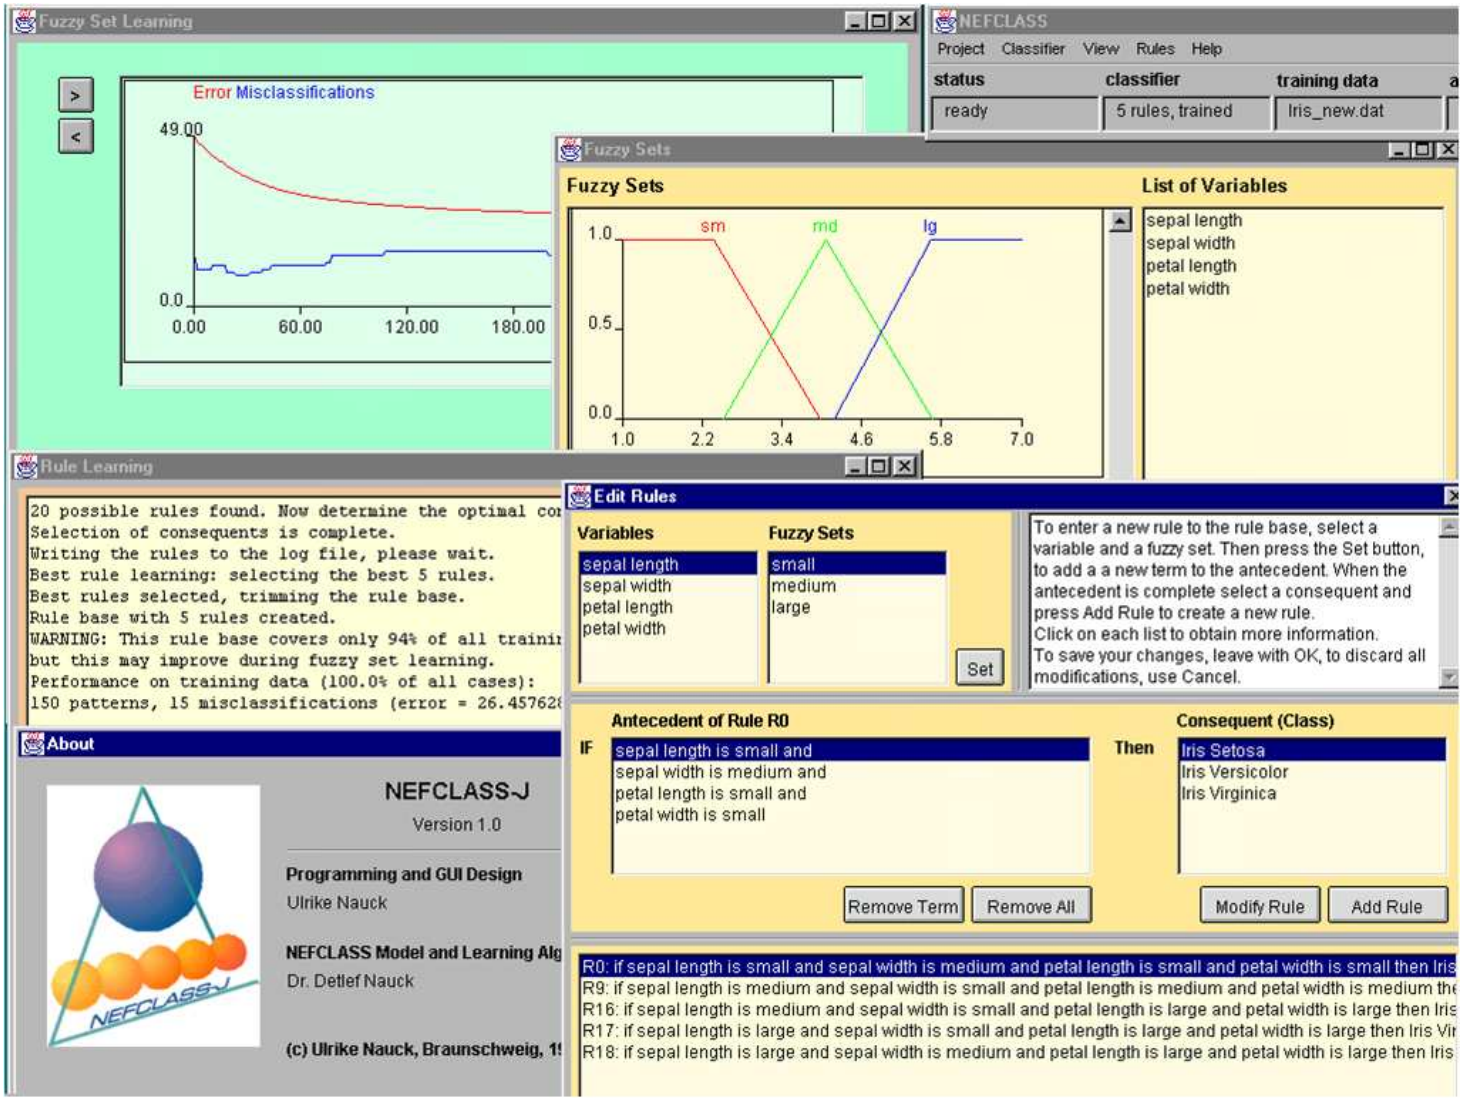
Fuzzy Set Learning
Error Misclassifications
49.00
0.0
0.00
60.00
120.00
180.00
NEFCLASS
Project Classifier View Rules Help
status
classifier
training data
ready
5 rules, trained
Iris_new.dat
Fuzzy Sets
Fuzzy Sets
List of Variables
sm
md
lg
1.0
0.5
0.0
1.0
2.2
3.4
4.6
5.8
7.0
sepal length
sepal width
petal length
petal width
Rule Learning
20 possible rules found. Now determine the optimal co
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 traini
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
Variables
Fuzzy Sets
sepal length
sepal width
petal length
petal width
small
medium
large
Set
To enter a new rule to the rule base, select a variable and a fuzzy set. Then press the Set button, to add a a new term to the antecedent. When the antecedent is complete select a consequent and press Add Rule to create a new rule.
Click on each list to obtain more information.
To save your changes, leave with OK, to discard all modifications, use Cancel.
About
NEFCLASS-J
Version 1.0
Programming and GUI Design
Ulrike Nauck
NEFCLASS Model and Learning Alg
Dr. Detlef Nauck
(c) Ulrike Nauck, Braunschweig, 1
Antecedent of Rule R0
IF
sepal length is small and
sepal width is medium and
petal length is small and
petal width is small
Then
Consequent (Class)
Iris Setosa
Iris Versicolor
Iris Virginica
Remove Term
Remove All
Modify Rule
Add Rule
R0: if sepal length is small and sepal width is medium and petal length is small and petal width is small then Iris
R9: if sepal length is medium and sepal width is small and petal length is medium and petal width is medium the
R16: if sepal length is medium and sepal width is small and petal length is large and petal width is large then Iris
R17: if sepal length is large and sepal width is small and petal length is large and petal width is large then Iris Vi
R18: if sepal length is large and sepal width is medium and petal length is large and petal width is large then Iris

Beispiel: Qualitätskontrolle

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

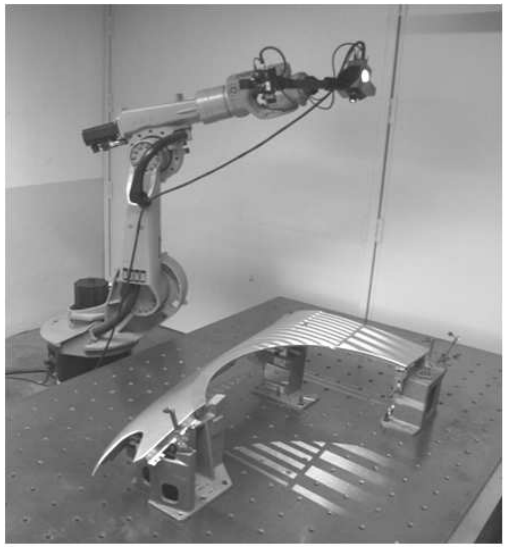

breuckmann

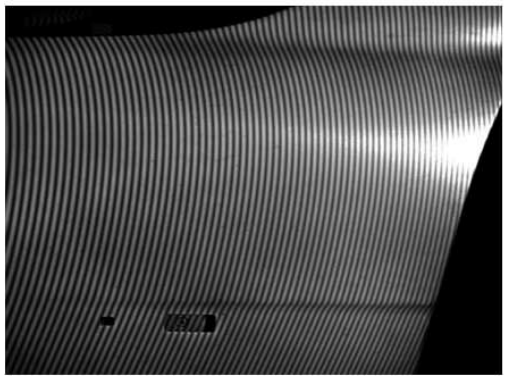

Triangulation und Gitterprojektion

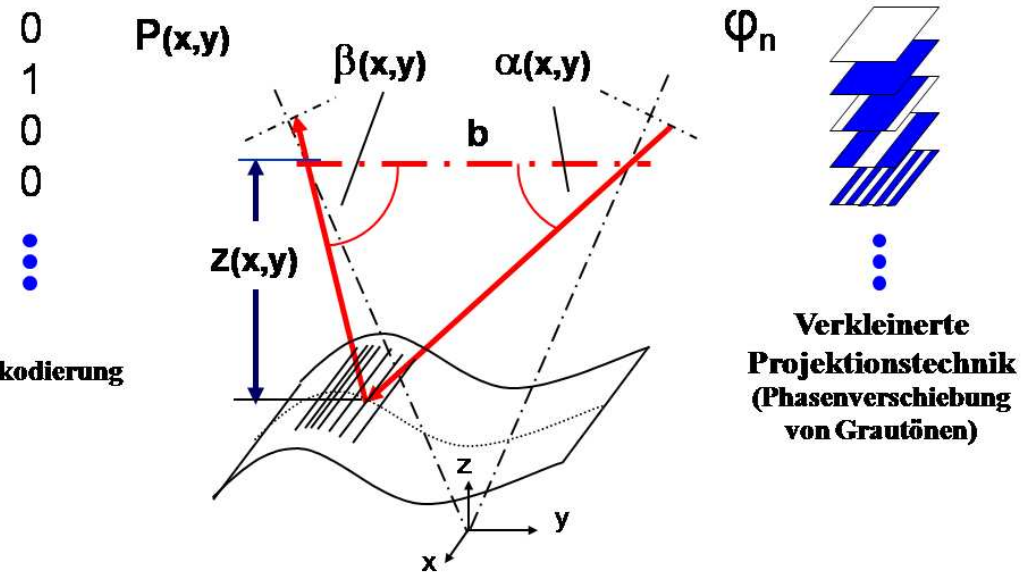

- hohe Punktdichte
- schnelle Datenansammlung
- genaue Messung
- kontakt- und harmlos

Datenverarbeitung

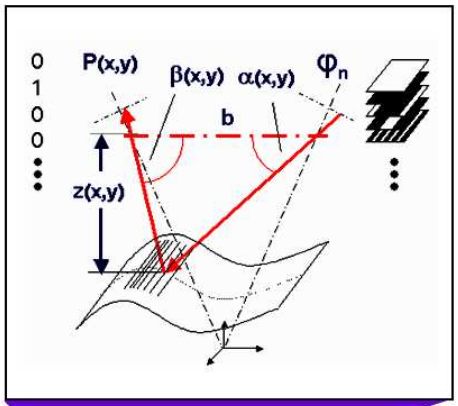

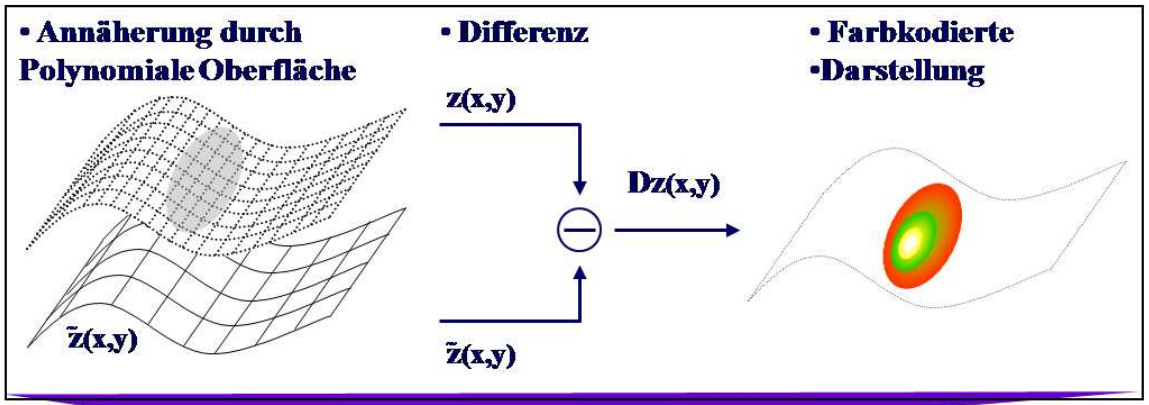

3-D-Daten-aufnahme → Nachverarbeitung → Erkennung von Abweichungen → Merkmalsanalyse

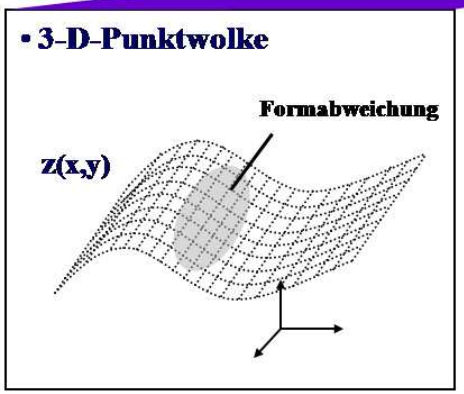

Farbkodierte Darstellung

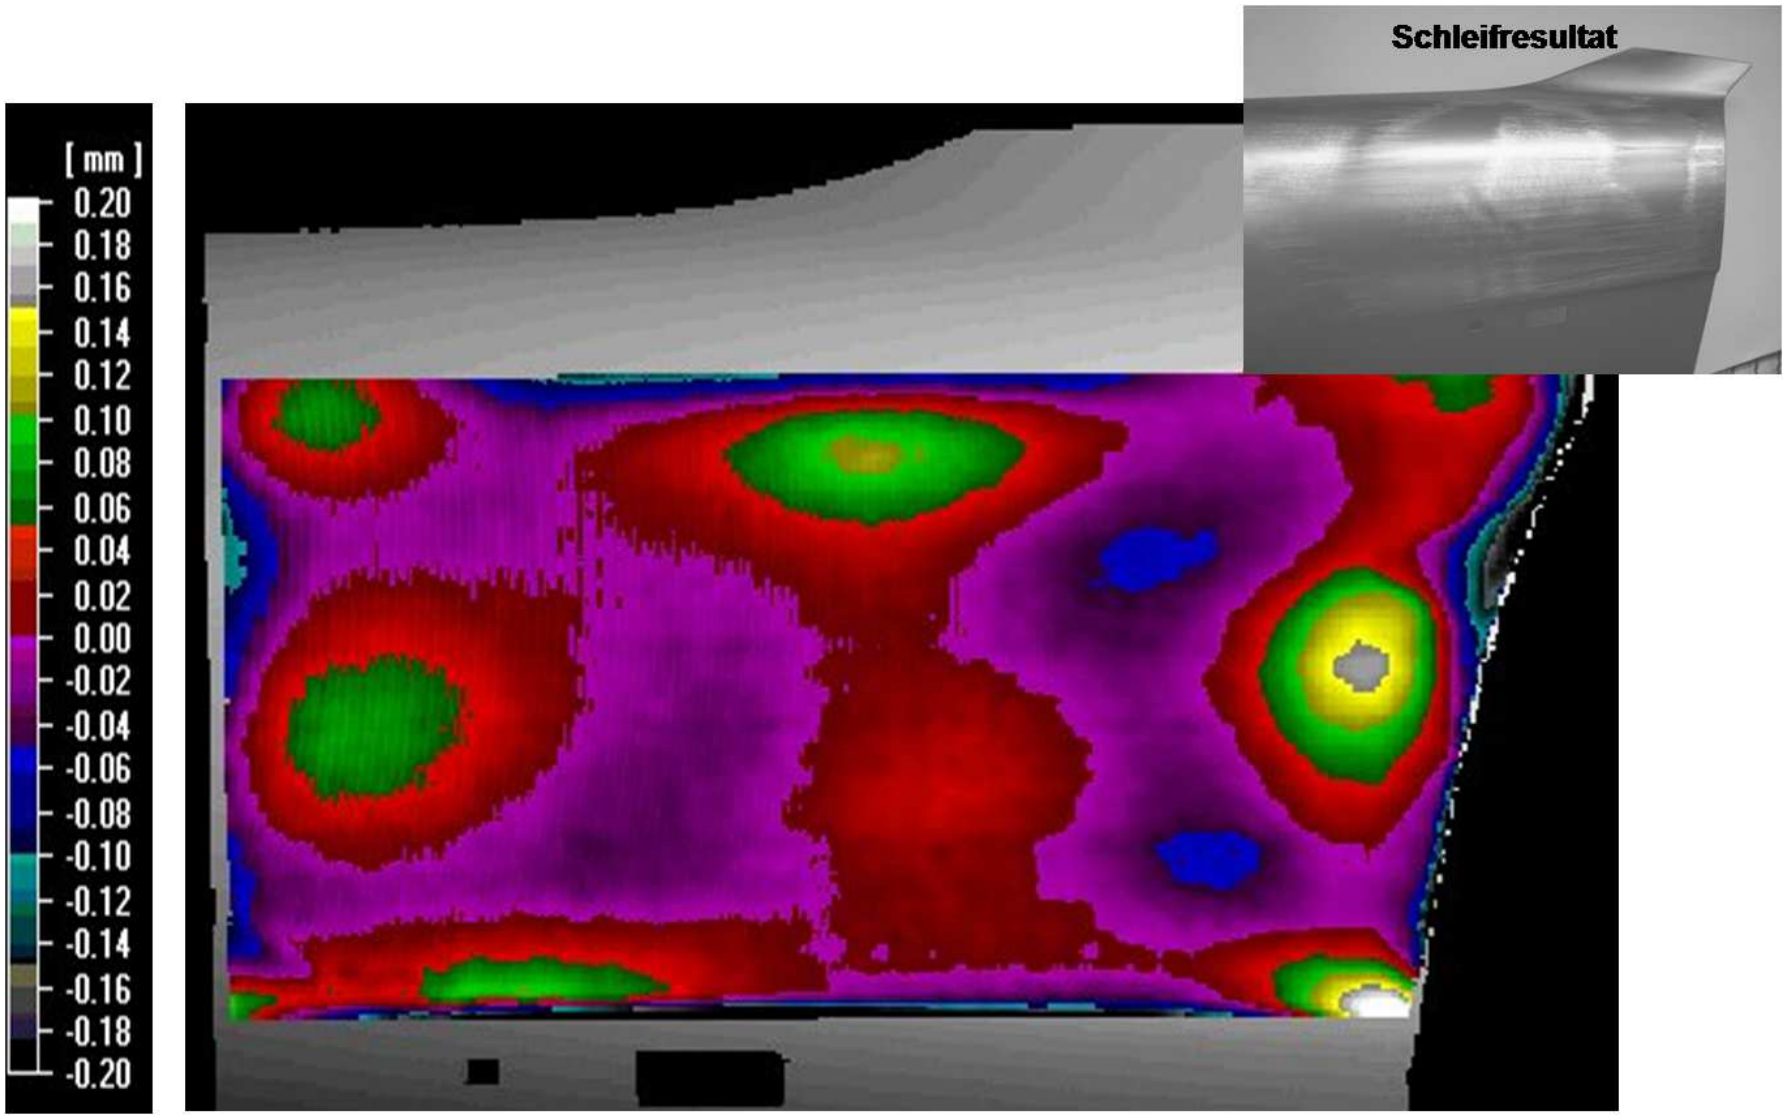

3D-Darstellung lokaler Oberflächendefekte

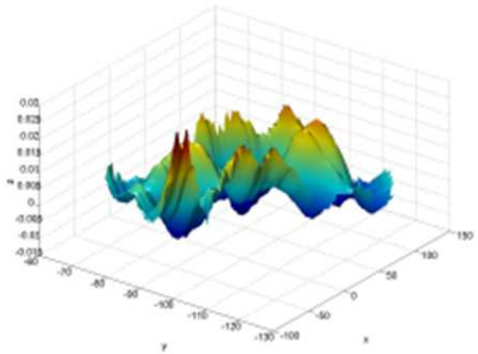

Unebene Oberfläche
Mehrere Einfallsstellen in Serie/benachbart

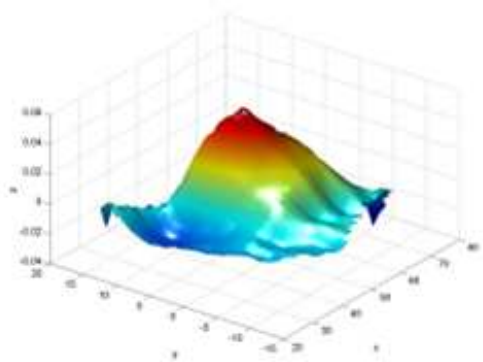

Walzenmarkierung
Lokale Glättung der Oberfläche

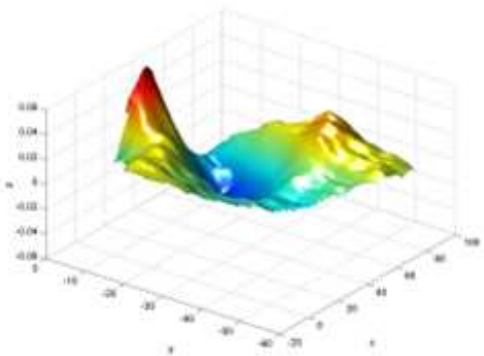

Einfallstelle
Leichte flach basierte Senke einwärts

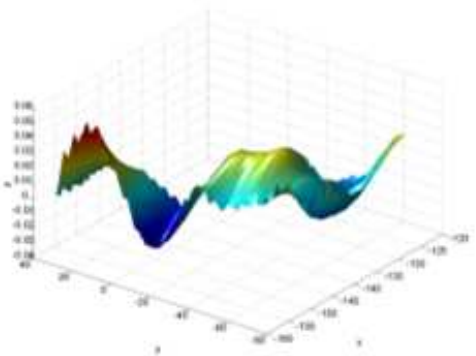

Wellplatte
Mehrere schwerere Faltungen in Serie

Charakteristik der Daten

9 Meisterstücke mit insgesamt 99 Defekten analysiert

Für jeden Defekt wurden 42 Merkmale berechnet

Typen sind eher unbalanciert

Seltene Klassen wurden verworfen

Einige extrem korrelierte Merkmale wurden verworfen (31 übrig)

Rangfolge der 31 Merkmale nach Wichtigkeit

Geschichtete 4-fache Kreuzvalidierung fürs Experiment

Anwendung und Ergebnisse

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%

Übersicht

Schwarm- und populationsbasierte Optimierung

Schwarm-Intelligenz

Bereich der KI, der intelligente Multi-Agentensysteme entwickelt
Inspiration durch das Verhalten bestimmter Tierarten, speziell

sozialer Insekten (z.B. Ameisen, Termiten, Bienen, etc.) und in Schwärmen lebender Tiere (z.B. Fische, Vögel, etc.)

Tiere dieser Arten können recht komplexe Aufgaben lösen (Finden von Nahrungsquellen, Wegesuche, Nestbau, etc.), indem sie kooperieren.

Wesentliche Ideen

I.A. ziemlich einfache Einzelindividuen mit begrenzten Fähigkeiten
Koordination ohne zentrale Steuerung, lediglich Selbstorganisation
Austausch von Informationen zwischen Individuen (Kooperation)

Klassifizierung der Verfahren nach Art des Informationsaustausches

Verfahren

Genetische/Evolutionäre Algorithmen

- Biologisches Vorbild: Evolution der Lebewesen
- Informationsaustausch durch Rekombination der Genotypen
- Jedes Individuum ist ein Lösungskandidat

Verfahren

Teilchenschwarmoptimierung

- Biologisches Vorbild: Futtersuche von Fisch- und Vogelschwärmen
- Informationsaustausch über einfache Aggregation der Einzellösungen
- Jedes Individuum ist ein Lösungskandidat

Ameisenkolonialgorithmen

- Biologisches Vorbild: Wegesuche zu Futterquellen durch Ameisen
- Informationsaustausch über Veränderung der Umgebung (Stigmergie, erweiterter Phänotyp nach Dawkins)
- Individuen konstruieren Lösungskandidaten

Übersicht

Teilchenschwarmoptimierung

© Eric T. Schulz http://www.eeb.uconn.edu/courses/eeb296/

© Ariel Bravy http://www.skphoton.com/albums/

Fische, Vögel suchen in Schwärmen nach ergiebigen Futterplätzen.
Orientierung anhand individueller Suche (kognitiver Anteil) und an anderen Mitgliedern des Schwarmes in ihrer Nähe (sozialer Anteil)
Außerdem: Leben im Schwarm schützt Individuen gegen Fressfeinde.

Biologische Vorbilder: Gnus

©http://www.birdsasart.com/

©http://takeatoothbrush.com/tanzaniaphotos/

Während Wandersaison: Zusammenschluss von 100000 Gnus
In Herde sinkt Risiko gefressen zu werden
Raubtiere können sich nicht leicht für einzelnes Opfer entscheiden und
verausgaben sich durch ineffiziente Jagd

Biologische Vorbilder: Gänse

©http://commons.wikimedia.org/wiki/Image:CanadianGeeseFlyingInVFormation.jpg

Optimaler Winkel in V-Formation fliegender Gänse: $34,2°$
Jede Gans nutzt Aufwind des voranfliegenden Tieres
Erspart viel Energie
Formationsgänse fliegen 70% weiter als einzelnes Tier

Biologische Vorbilder: Fische

©http://s3.amazonaws.com/xlsuite_production/assets/51840/fish-swarm.jpg

2-3 Artgenossen geben einzelnem Fisch im Schwarm Orientierung
Anpassung von Geschwindigkeit und Richtung, sodass Winkel zwischen Schwimmrichtung und nächsten Artgenossen: 45–135 °
Andere Fische werden ignoriert

Garantie, dass Schwarm ständig vorwärtsschwimmt und Abweichler nicht Gesamtrichtung beeinflussen

Biologische Vorbilder: Kaiserpinguine

©http://aroma.pblogs.gr/

10% weniger Energie für lebenswichtige Körperfunktionen durch Wärmen in Kolonie

Körpertemperatur um 0,5°C niedriger als einzeln stehende Pinguine

Biologische Vorbilder: Wüstenheuschrecken

©http://dusteye.files.wordpress.com/

Dichte in Schwärmen: 73,8 Wüstenheuschrecken/m^2

Eigentlich Einzelgänger, rotten sich nur bei Hunger zusammen

Jede versucht, Hinterteil des Vordermanns zu fressen

Gleichzeitig: Kannibalen weichen Attacken ihres Hintermanns aus

Biologische Vorbilder: Seemöwen

©http://www.gonomad.com/beourguest/

Möwe beim Landen: 30 cm Abstand zu ihren Artgenossen, damit diese sie nicht angreifen.
Die meisten Möwen wissen das.
Studie: 7% der beobachteten Vögel missachteten Distanzregel.

Biologische Vorbilder: Schafe

©http://www.delaval-us.com/

Winkel zwischen grasenden Schafen: 55° im Durchschnitt
Dadurch oft direkter Körperkontakt
Herde bleibt eng zusammen, lässt sich so leichter führen
Bedürfnis kann man gezielt herbeizüchten

Biologische Vorbilder: Flamingos

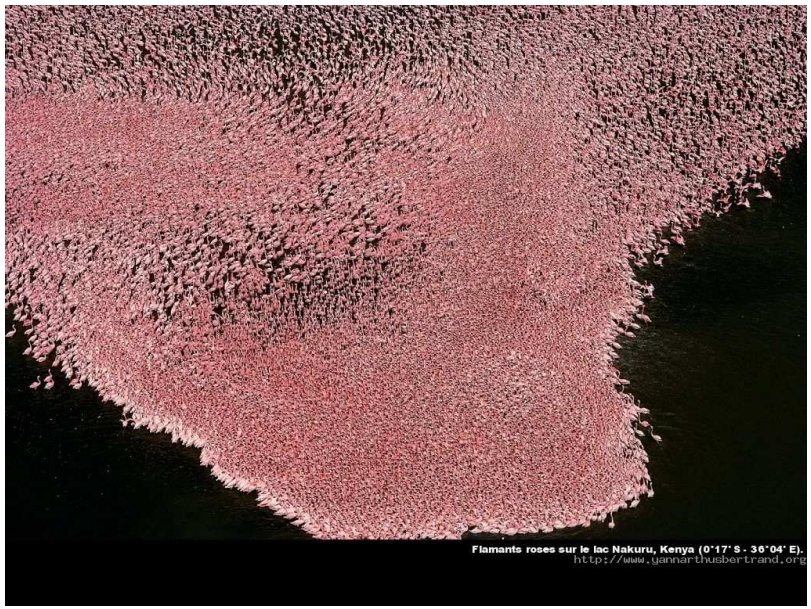

©http://www.yannarthusbertrand.com/

Paarungsstimmung: ab 20 Flamingos im Schwarm
Bei weniger Vögeln sinkt Geburtenrate drastisch
In amerikanischen Zoos: nur 1/4 aller Schwärme hat Nachkommen
Wildpopulationen: mehrere Tausend Tiere

Biologische Vorbilder: Zebras

©http://lh5.ggpht.com/_RuFhd_V_a6E/R8iVyGsA28I/AAAAAAAABSc/ybuBSqYsIro/

Vorsprung am Wasserloch der vordersten Gruppe einer Herde zum Rest: 4,4 min im Durchschnitt

Leittiere trinken, bei anderen verringert sich Wahrscheinlichkeit logarithmisch

Für 10. Zebra: 13%

Erfahrenen Leittiere: für Herde besonders wichtig

Biologische Vorbilder: Wanderameisen

30000 Beutetiere pro Stunde kann ein Zug aus 200000 Wanderameisen erlegen
Insekten lenken sich nicht zu sehr voneinander ab
Dadurch kein Stau und Fressrate bleibt möglichst hoch
Grund: jede Ameise bekommt nur mit, was sich im Winkel von 90° vor ihren Antennen abspielt

©http://en.wikipedia.org/wiki/Image:Safari_ants_tunnel.jpg

Teilchenschwarmoptimierung

Particle Swarm Optimization [Kennedy and Eberhart, 1995]

Motivation: Verhalten von z.B. Fischschwärmen bei der Futtersuche: zufälliges Ausschwärmen, aber stets auch Rückkehr zum Schwarm, Informationsaustausch zwischen Mitgliedern

Ansatz: verwende statt nur einzelnen aktuellen Lösungskandidaten „Schwarm“ von m Lösungskandidaten

Voraussetzung: $\Omega \subseteq \mathbb{R}^n$ und somit zu optimierende (o.B.d.A.: zu maximierende) Funktion $f : \mathbb{R}^n \to \mathbb{R}$

Vorgehen: fasse jeden Lösungskandidaten als „Teilchen“ auf, das Ort $\boldsymbol{x}_i$ im Suchraum und Geschwindigkeit $\boldsymbol{v}_i$ hat ($i = 1, \ldots, m$)

Vereinigt Elemente der bahnorientierten Suche (z.B. Gradientenverfahren) und populationsbasierter Suche (z.B. EA)

Teilchenschwarmoptimierung

Aktualisierung für Ort und Geschwindigkeit des i-ten Teilchens:

$$\boldsymbol{v}_i(t+1) = \alpha \boldsymbol{v}_i(t) + \beta_1 \left(\boldsymbol{x}_i^{(\text{lokal})}(t) - \boldsymbol{x}_i(t) \right) + \beta_2 \left(\boldsymbol{x}^{(\text{global})}(t) - \boldsymbol{x}_i(t) \right)$$

$$\boldsymbol{x}_i(t+1) = \boldsymbol{x}_i(t) + \boldsymbol{v}_i(t)$$

Parameter: β_1, β_2 zufällig in jedem Schritt, α mit t abnehmend

$\boldsymbol{x}_i^{(\text{lokal})}$ ist **lokales Gedächtnis** des Individuums (Teilchens): der beste Ort im Suchraum, den Teilchen bisher besucht hat, d.h.

$$\boldsymbol{x}_i^{(\text{lokal})} = \boldsymbol{x}_i \left(\arg\max_{u=1}^{t} f(\boldsymbol{x}_i(u)) \right)$$

$\boldsymbol{x}^{(\text{global})}$ ist **globales Gedächtnis** des Schwarms: der beste Ort im Suchraum, den Individuum des Schwarms bisher besucht hat (beste bisher gefundene Lösung), d.h.

$$\boldsymbol{x}^{(\text{global})}(t) = \boldsymbol{x}_j^{(\text{lokal})}(t) \quad \text{mit} \quad j = \arg\max_{i=1}^{m} f\left(\boldsymbol{x}_i^{(\text{lokal})} \right)$$

Algorithmus 1 Teilchenschwarmoptimierung

1: **for each** Teilchen i {
2: $\quad \boldsymbol{x}_i \leftarrow$ wähle zufällig im Suchraum Ω
3: $\quad \boldsymbol{v}_i \leftarrow 0$
4: }
5: **do** {
6: $\quad$ **for each** Teilchen i {
7: $\quad\quad y \leftarrow f(\boldsymbol{x}_i)$
8: $\quad\quad$ **if** $y \geq f\left(\boldsymbol{x}_i^{(\text{lokal})}\right)$ {
9: $\quad\quad\quad \boldsymbol{x}_i^{(\text{lokal})} \leftarrow \boldsymbol{x}_i$
10: $\quad\quad$ }
11: $\quad\quad$ **if** $y \geq f\left(\boldsymbol{x}_i^{(\text{global})}\right)$ {
12: $\quad\quad\quad \boldsymbol{x}^{(\text{global})} \leftarrow \boldsymbol{x}_i$
13: $\quad\quad$ }
14: $\quad$ }
15: $\quad$ **for each** Teilchen i {
16: $\quad\quad \boldsymbol{v}_i(t+1) \leftarrow \alpha \cdot \boldsymbol{v}_i(t) + \beta_1 \left(\boldsymbol{x}_i^{(\text{lokal})}(t) - \boldsymbol{x}_i(t)\right) + \beta_2 \left(\boldsymbol{x}^{(\text{global})}(t) - \boldsymbol{x}_i(t)\right)$
17: $\quad\quad \boldsymbol{x}_i(t+1) \leftarrow \boldsymbol{x}_i(t) + \boldsymbol{v}_i(t)$
18: $\quad$ }
19: } **while** Terminierungskriterium ist nicht erfüllt

Erweiterungen

Beschränkter Suchraum: ist Ω echte Teilmenge des $\mathbb{R}^n$ (z.B. Hyperwürfel $[a, b]^n$), so werden Teilchen an Grenzen des Suchraums reflektiert

Lokale Umgebung eines Teilchens: statt des globalen Gedächtnisses des Schwarms wird bestes lokales Gedächtnis nur eines Teils des Schwarms verwendet, z.B. Teilchen, die sich in näherer Umgebung des zu aktualisierenden Teilchens befinden

Automatische Parameteranpassung: z.B. Anpassung der Schwarmgröße (Teilchen, deren lokales Gedächtnis deutlich schlechter ist als das der Teilchen in ihrer Nähe, werden entfernt)

Diversitätskontrolle: vorzeitige Kovergenz auf suboptimalen Lösungen soll verhindert werden, dazu kann z.B. bei Aktualisierung der Geschwindigkeit zusätzliche Zufallskomponente eingeführt werden, welche Diversität erhöht

Teilchenschwarmoptimierung

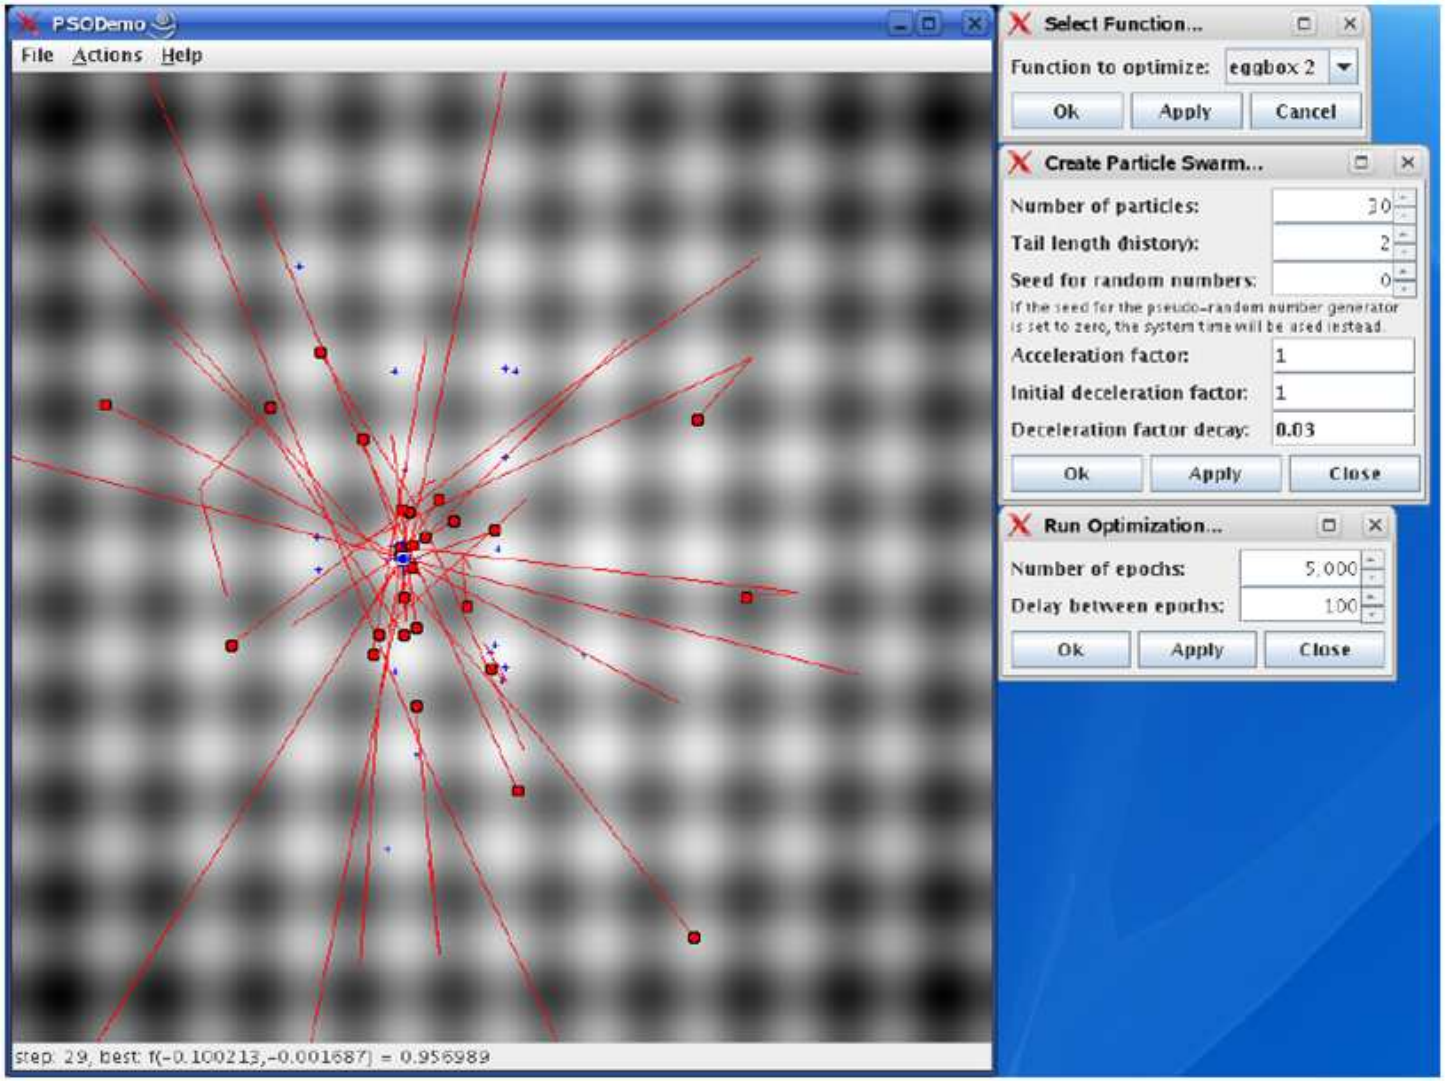

Übersicht

Ameisenkolonieoptimierung

© PeTA http://www.helpingwildlife.com/ants.asp

© NickLyonMedia http://nicklyon.orchardhostings4.co.uk

Da gefundenes Futter zur Versorgung der Nachkommen zum Nest transportiert werden muss, bilden Ameisen Transportstraßen Weglängen zu Futterplätzen werden annähernd minimiert

Doppelbrückenexperiment [Goss et al., 1989]

Ameisennest und Futterquelle werden durch Doppelbrücke verbunden (beiden Zweige der Brücke sind verschieden lang)

Experiment mit argentinischer Ameise *Iridomyrmex Humilis*: diese Ameisenart ist (wie fast alle anderen auch) fast blind (Ameisen können also nicht sehen, welcher Weg kürzer ist)

Schon nach wenigen Minuten: in meisten Versuchen benutzten fast alle Ameisen kürzeren Weg

Erklärung:

Auf kürzerem Weg erreichen Ameisen Futter schneller (Ende des kürzeren Weges erhält daher (am Anfang) mehr Pheromon)
Auf Rückweg wird wegen entstandener Pheromondifferenz mit höherer W'keit kürzerer Weg gewählt (führt zu einer Verstärkung der Pheromondifferenz)

Doppelbrückenexperiment

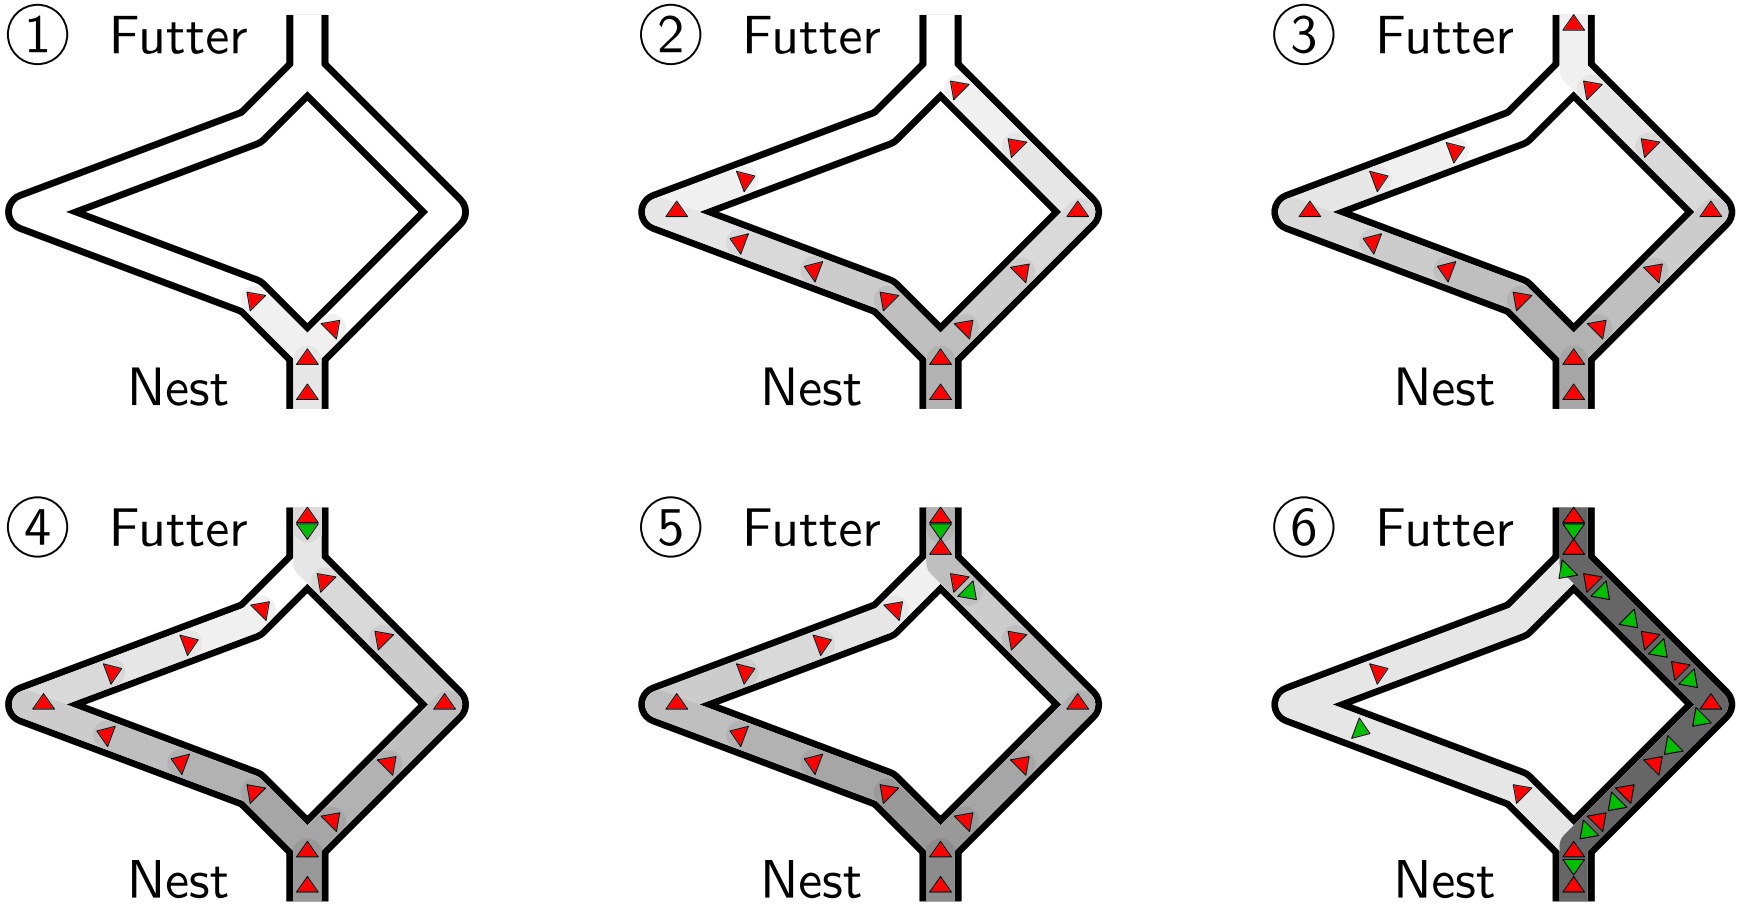

Doppelbrückenexperiment: Prinzip

Kürzerer Weg wird systematisch verstärkt (Autokatalyse): mehr Pheromon auf Weg $\longleftrightarrow$ mehr Ameisen wählen Weg

Beachte: kürzerer Weg wird nur gefunden, weil Ameisen sowohl auf Hin- als auch auf Rückweg Pheromon ablegen

Wird z.B. nur auf Hinweg Pheromon abgelegt:

- Auf dem Hinweg zur Futterquelle kann keiner der beiden Wege bevorzugt werden, da keine Pheromondifferenz vorliegt oder systematisch entsteht
- Am Vereinigungspunkt der Brücken verringert sich Verhältnis der Pheromonmengen im Laufe der Zeit und verschwindet schließlich nahezu
- Durch zufällige Fluktuationen in Wegewahl konvergiert Wegesuche ggf. dennoch zufällig(!) auf einen der beiden Brückenzweige

Analog: wenn Pheromon nur auf Rückweg abgelegt

Doppelbrückenexperiment

Beachte: kürzerer Weg wird gefunden, weil schon zu Beginn beide Zweige der Brücke zur Verfügung stehen und auf beiden kein Pheromon liegt

Ende des kürzeren Weges wird früher von mehr Ameisen erreicht

Unterschiedliche Mengen an Pheromon auf beiden Wegen ergeben einen sich selbst verstärkenden Prozess

Fragen: Was passiert, wenn durch Veränderung der Umgebung neuer Weg möglich wird, der kürzer ist als bisheriger?

Wird auf diesen kürzeren Weg gewechselt?

Antwort: Nein! [Goss et al., 1989]

Ist erst einmal ein Weg etabliert, so wird dieser beibehalten

Nachweis durch 2. Brückenexperiment: anfangs nur längerer Brückenzweig da, kürzerer später hinzugefügt

Mehrheit der Ameisen benutzen weiter längeren Weg, nur seltenen Wechsel auf kürzeren Weg

Ameisenkolonieoptimierung

Ant Colony Optimization [Dorigo and Stützle, 2004]

Motivation: Ameisen einiger Arten finden kürzeste Wege zu Futterquellen durch Legen und Verfolgen von Pheromon („Duftmarken“)

- Intuitiv: kürzere Wege erhalten in gleicher Zeit mehr Pheromon
- Wege werden zufällig nach vorhandenen Pheromonmenge gewählt (es ist um so wahrscheinlicher, dass ein Weg gewählt wird, je mehr Pheromon sich auf Weg befindet)
- Menge des ausgebrachten Pheromons kann von Qualität und Menge des gefundenen Futters abhängen

Grundprinzip: Stigmergie (engl. stigmergy)

- Ameisen kommunizieren indirekt über Pheromonablagerungen
- Stigmergie (indirekte Kommunikation durch Veränderung der Umgebung) ermöglicht global angepasstes Verhalten aufgrund lokaler Informationen

Natürliche und künstliche Ameisen

abstrahiere zu Suche nach bestem Weg in gewichtetem Graphen

Problem: Kreise, die sich selbst verstärken (durchläuft Ameise Kreis, erzeugt sie durch abgelegtes Pheromon Tendenz, Kreis erneut zu durchlaufen)

Abhilfe: Ablegen von Pheromon erst nach Konstruktion des ganzen Weges (Entfernen von Kreisen, bevor Pheromon abgelegt wird)

Problem: Ggf. konzentriert sich Suche auf am Anfang konstruierte Lösungskandidaten (vorzeitige Konvergenz)

Abhilfe: Pheromonverdunstung (spielt in Natur geringe Rolle)

Nützliche Erweiterungen/Verbesserungen

Abgelegte Pheromonmenge hängt von Lösungsgüte ab
Einbringen von Heuristiken in Kantenwahl (z.B. Kantengewicht)

Ameisenkolonieoptimierung

Voraussetzungen: kombinatorisches Optimierungsproblem mit konstruktiver Methode, zur Erzeugung eines Lösungskandidaten
Vorgehen: Lösungen werden durch Folge von Zufallsentscheidungen konstruiert, wobei jede Entscheidung Teillösung erweitert
Entscheidungsfolge = Pfad in Entscheidungsgraphen (auch: Konstruktionsgraphen)
Ameisen sollen Pfade durch Entscheidungsgraphen erkunden und besten (kürzesten, billigsten) Weg finden
Ameisen markieren benutzte Kanten des Graphen mit Pheromon
$\Rightarrow$ andere Ameisen werden zu guten Lösungen geleitet
Pheromon verdunstet in jeder Iteration, damit einmal ausgebrachtes Pheromon System nicht zu lange beeinflußt („Vergessen“ veralteter Information)

Anwendung auf TSP

Darstellung des Problems durch $n \times n$ Matrix $\boldsymbol{D} = (d_{ij})_{1 \leq i,j \leq n}$
n Städte mit Abständen d_{ij} zwischen Städte i und j
Beachte: $\boldsymbol{D}$ kann asymmetrisch sein, aber $\forall i \in \{1, \ldots, n\} : d_{ii} = 0$
Pheromoninformation als $n \times n$ Matrix $\Phi = (\phi_{ij})_{1 \leq i,j \leq n}$
Pheromonwert $\phi_{ij} (i \neq j)$ gibt an, wie wünschenswert es ist, Stadt j direkt nach Stadt i zu besuchen (ϕ_{ii} nicht benötigt)
Φ muss nicht notwendig symmetrisch sein/gehalten werden
Alle ϕ_{ij} werden mit gleichen kleinen Wert initialisiert (anfangs liegt auf allen Kanten gleiche Menge Pheromon)
Ameisen durchlaufen (durch Pheromon) Hamiltonkreise (sie markieren Kanten des durchlaufenden Hamiltonkreises mit Pheromon, wobei ausgebrachte Pheromonmenge der Lösungsqualität entspricht)

Lösungskonstruktion

Jede Ameise hat „Gedächtnis“ C, welche Indizes der noch nicht besuchten Städte enthält

Jede besuchte Stadt wird aus Menge C entfernt

Gedächtnis gibt es im biologischen Vorbild nicht!

Ameise wird in zufällig bestimmter Stadt gesetzt (Anfang der Rundreise)

Ameise wählt noch nicht besuchte Stadt und begibt sich in diese: in Stadt i wählt Ameise (unbesuchte) Stadt j mit W'keit

$$p_{ij} = \frac{\phi_{ij}}{\sum_{k \in C} \phi_{ik}}.$$

Wiederhole Schritt 2 bis alle Städte besucht

Pheromonaktualisierung

1. **Verdunstung/Evaporation**
   alle ϕ_{ij} werden um Bruchteil η (evaporation) verringert:

$$\forall i, j \in \{1, \ldots, n\} : \phi_{ij} = (1 - \eta) \cdot \phi_{ij}$$

2. **Verstärkung konstruierter Lösungen**
   Kanten der konstruierten Lösungen werden mit zusätzlicher Menge an Pheromon belegt, die Lösungsqualität entspricht:

$$\forall \pi \in \Pi_t : \phi_{\pi(i)\pi((i \bmod n)+1)} = \phi_{\pi(i)\pi((i \bmod n)+1)} + Q(\pi)$$

   Π_t ist Menge der im Schritt t konstruierten Rundreisen (Permutationen), Qualitätsfunktion: z.B. inverse Reiselänge

$$Q(\pi) = c \cdot \left(\sum_{i=i}^{n} d_{\pi(i)\pi((i \bmod n)+1)} \right)^{-1}$$

   „Je besser Lösung, desto mehr Pheromon erhalten deren Kanten.“

Problem des Handlungsreisenden

Algorithmus 2 Ameisenkolonieoptimierung für das TSP

initialisiere alle Matrixelemente ϕ_{ij}, $1 \leq i, j \leq n$, auf kleinen Wert ϵ
do {
  for each Ameise { /* konstruiere Lösungskandidaten */
    $C \leftarrow \{1, \ldots, n\}$ /* Menge der zu besuchenden Städte */
    $i \leftarrow$ wähle zufällig Anfangsstadt aus C
    $C \leftarrow C \setminus \{i\}$ /* entferne sie aus den unbesuchten Städten */
    while $C \neq \emptyset$ { /* solange nicht alle Städte besucht wurden */
      $j \leftarrow$ wähle nächste Stadt der Reise aus C mit W'keit p_{ij}
      $C \leftarrow C \setminus \{j\}$ /* entferne sie aus den unbesuchten Städten */
      $i \leftarrow j$ /* und gehe in die ausgewählte Stadt */
    }
  }
  aktualisiere Pheromon-Matrix Φ nach Lösungsgüte
} **while** Terminierungskriterium ist nicht erfüllt

Erweiterungen und Alternativen

Bevorzuge nahe Städte: (analog zur NächstenNachbarHeuristik)
Gehe von Stadt i zu Stadt j mit W'keit

$$p_{ij} = \frac{\phi_{ij}^{\alpha} \tau_{ij}^{\beta}}{\sum_{k \in C} \phi_{ik}^{\alpha} \tau_{ik}^{\beta}}$$

wobei C Menge der Indizes der unbesuchten Städte und $\tau_{ij} = d_{ij}^{-1}$

Tendiere zur Wahl der besten Kante: (greedy)
mit W'keit p_{exploit} gehe von Stadt i zur Stadt j_{best} mit

$$j_{\text{best}} = \arg\max_{j \in C} \phi_{ij} \quad \text{bzw.} \quad j_{\text{best}} = \arg\max_{j \in C} \phi_{ij}^{\alpha} \tau_{ij}^{\beta}$$

und benutze p_{ij} mit W'keit $1 - p_{\text{exploit}}$

Verstärke beste bekannte Rundreise: (elitist)
Lege zusätzliches Pheromon auf besten bisher bekannten Rundreise ab (z.B. Bruchteil Ameisen, die sie zusätzlich ablaufen)

Lokale Verbesserungen der Rundreise

Verknüpfung mit lokaler Lösungsverbesserung ist oft vorteilhaft: Vor Pheromonaktualisierung wird erzeugte Rundreise lokal optimiert (einfache Modifikationen wird auf Verbesserung überprüft)

lokale Optimierungen benutzen z.B. folgende Operationen:

- **Rekombination nach Entfernen von zwei Kanten** (2-opt) entspricht dem „Umdrehen“ einer Teil-Rundreisen
- **Rekombination nach Entfernen von drei Kanten** (3-opt) entspricht dem „Umdrehen“ zweier Teil-Rundreisen
- **Eingeschränkte Rekombination** (2.5-opt)
- **Austausch benachbarter Städte**
- **Permutation benachbarter Triplets**

„Teure“ lokale Optimierungen: nur auf beste gefundene Lösung oder die in einer Iteration beste Lösung angewanden

Ameisenkolonieoptimierung

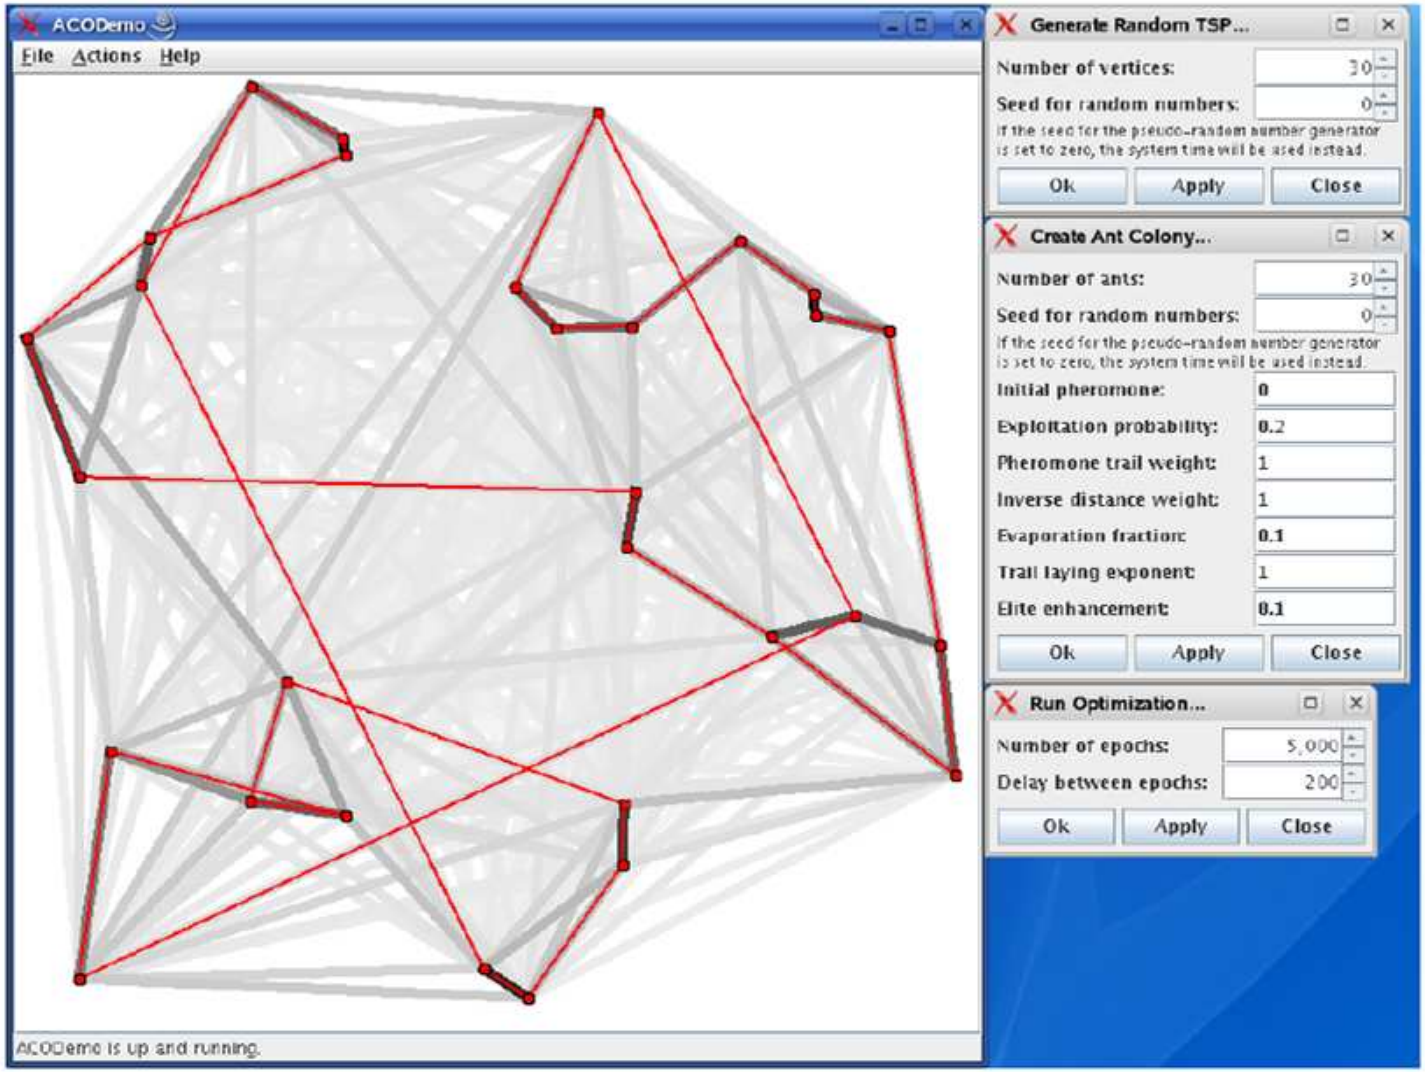

Allg. Anwendung zur Optimierung

Grundsätzliches Prinzip

Formuliere Problem als Suche in (Entscheidungs-)Graphen, Lösungskandidaten müssen durch Kantenmengen beschreibbar sein, (beachte: es muss sich nicht notwendigerweise um Pfade handeln!)

Allgemeine Beschreibung: im folgenden jeweils angegeben:

- Knoten, Kanten des Entscheidungs-/Konstruktionsgraphen
- Einzuhaltende Nebenbedingungen
- Bedeutung des Pheromons auf Kanten (und evtl. Knoten)
- Nutzbare heuristische Hilfsinformation
- Konstruktion eines Lösungskandidaten

Algorithmisches Vorgehen ist i.W. analog zu Vorgehen beim TSP

Allg. Anwendung zur Optimierung: TSP

Knoten und Kanten des Entscheidungs-/Konstruktionsgraphen: die zu besuchenden Städte und ihre Verbindungen, die Verbindungen sind gewichtet (Abstand, Zeit, Kosten)

einzuhaltende Nebenbedingungen: besuche jede Stadt genau 1x

Bedeutung des Pheromons auf den Kanten: wie wünschenwert ist es, Stadt j nach Stadt i zu besuchen

nutzbare heuristische Hilfsinformation: Abstand der Städte, bevorzuge nahe Städte

Konstruktion eines Lösungskandidaten: ausgehend von zufällig gewählter Stadt wird stets zu einer weiteren, noch nicht besuchten Stadt fortgeschritten

Allg. Anwendung zur Optimierung: Zuordnungsproblem

Ordne n Aufgaben zu m Arbeiter (Personen, Maschinen): Minimierung der Summe der Zuordnungskosten d_{ij} unter Einhaltung maximaler Kapazitäten ρ_j bei gegebenen Kapazitätskosten r_{ij}, $1 \leq i \leq n$, $1 \leq j \leq m$

- Jede Aufgabe und jeder Arbeiter = Knoten des Konstruktionsgraphen (Kanten tragen die Zuordnungskosten d_{ij})
- Jede Aufgaben muss genau einem Arbeiter zugeordnet werden (Kapazitäten der Arbeiter nicht überschreiten)
- Pheromonwerte auf Kanten beschreiben, wie wünschenswert Zuordnung einer Aufgabe an Arbeiter ist
- Inverse absolute oder relative r_{ij} oder inverse d_{ij}
- Wähle schrittweise Kanten (müssen keinen Pfad bilden), übergehe Kanten von bereits zugeordneten Aufgaben (bestrafe Lösungen, die Nebenbedingungen verletzen (Kostenerhöhung))

Allg. Anwendung zur Optimierung: Rucksackproblem

Wähle aus n Objekten mit zugeordnetem Wert w_i, Gewicht g_i, Volumen v_i, etc. $1 \leq i \leq n$, Teilmenge maximalen Wertes aus, sodass Maximalwerte für Gewicht, Volumen, etc. eingehalten

- Jedes Objekt = Knoten des Konstruktionsgraphen (Knoten tragen Objektwerte w_i, Kanten nicht benötigt)
- Maximalwerte für Gewicht, Volumen, etc. müssen eingehalten werden
- Pheromonwerte: nur Knoten zugeordnet (sie beschreiben, wie wünschenswert Auswahl des zugehörigen Objektes)
- Verhältnis von Objektwert zu relativem Gewicht, Volumen, etc. wobei in den Verhältnissen die Maximalwerte berücksichtigt werden können
- Wähle schrittweise Knoten aus, wobei in jedem Schritt sichergestellt, dass Maximalwerte eingehalten

Konvergenz der Suche

betrachte „Standardverfahren“ mit folgenden Eigenschaften:

- Verdunstung des Pheromons mit konstantem Faktor von allen Kanten
- Nur auf Kanten des besten, bisher gefundenen Lösungskandidaten wird Pheromon abgelegt (strenges Eliteprinzip)
- $\exists$ Untergrenze ϕ_{min} für Pheromonwerte der Kanten, welche nicht unterschritten wird
- Standardverfahren konvergiert in W'keit gegen Lösung, d.h. mit $t \to \infty$ geht W'keit, dass Lösung gefunden wird, gegen 1
- Lässt man Untergrenze ϕ_{min} für Pheromonwerte „genügend langsam“ gegen 0 gehen ($\phi_{\text{min}} = \frac{c}{\ln(t+1)}$ mit Schrittzahl t und Konstante c), kann man zeigen, dass für $t \to \infty$ jede Ameise der Kolonie Lösung mit gegen 1 gehender W'keit konstruiert

Zusammenfassung

Schwarm- und populationsbasierte Algorithmen: **Heuristiken zur Lösung von Optimierungsproblemen**

Ziel: Finden guter Näherungslösungen

Problem der lokalen Optima: Reduzierung durch bessere Durchforstung des Suchraums

Wichtig: **Informationsaustausch** zwischen Individuen (je nach Prinzip: verschiedene Algorithmentypen)

Teilchenschwarmoptimierung

- Optimierung einer Funktion mit reellen Argumenten
- Informationsaustausch durch Orientierung an Nachbarn

Ameisenkolonieoptimierung

- Suche nach besten Wegen (abstrakt: in einem Entscheidungsgraphen)
- Informationsaustausch durch Veränderung der Umgebung (Stigmergie)

Literatur

Clerc, M. (2010).
Particle Swarm Optimization.
John Wiley & Sons.

Dorigo, M. and Stützle, T. (2004).
Ant Colony Optimization.
MIT Press, Cambridge, MA, USA.

Goss, S., Aron, S., Deneubourg, J.-L., and Pasteels, J. M. (1989).
Self-organized shortcuts in the argentine ant.
Naturwissenschaften, pages 579–581.

Kennedy, J. and Eberhart, R. (1995).
Particle swarm optimization.
In *Proc. IEEE Int'l. Conf. on Neural Networks*, pages 1942–1948, Perth, Australia.