KI Methoden in der Schadensprüfung und Überwachung

Autonome und robuste Datenanalyse mit Maschinellen Lernen und KI in der Schadensprüfung und Überwachung

Priv.-Doz. Dr. Stefan Bosse
Universität Bremen, FB Mathematik & Informatik
19.2.2018
sbosse@uni-bremen.de

1. Inhalt

1. Inhalt 1
2. Einführung 2
2.1. Schadensprüfung und Überwachung . . . 2
2.2. Einsatz von KI . . . 2
2.3. Maschinelles Lernen . . . 3
2.4. Maschinelles Lernen: Material und Struktur . . . 6
2.5. Maschinelles Lernen: SHM und Hybride/Composites . . . 6
2.6. Virtuelles Trainieren . . . 6
3. Algorithmen und Modelle 7
3.1. Modell: Entscheidungsbaum . . . 7
3.2. Modell: Neuronales Netzwerk . . . 8
3.3. Agentenbasierte Verfahren . . . 10
4. Anwendungsbeispiele 10
4.1. Modellierung von Composites mit ANN . . . 11
4.2. Automatische Signalanalyse mit Agenten . . . 11
4.3. Ereignisbasierte Sensorverarbeitung mit Agenten . . . 14
4.4. Lasterkennung mit Verteilten Lernen . . . 15
4.5. Strukturüberwachung von Verbundwerkstoffen . . . 16
5. Zusammenfassung 17
6. Referenzen 18

2. Einführung

2.1. Schadensprüfung und Überwachung

> *Untersuchung des Material- und Strukturverhaltens von Proben und Bauteilen unter verschiedenen Belastungs- und Einsatzsituationen*

Ziele

- Erlangung von Materialparametern durch Experimente
- Entwicklung neuer Materialien ↠ **Material Informatik**!
- Erkenntnisse über und **Verständnis** von Schadensmechanismen (Ursachen und Ausbreitung)
- **Bauteilüberwachung** zur Betriebszeit (SHM)
- **Optimierung** von Bauteilen, Verbundmaterialien, und Einsatzsituationen
- Vorhersage **Lebensdauerzyklus** zur Betriebszeit
- Optimierte und dynamisierte **Wartung**

2.2. Einsatz von KI

> *Es fallen große Datenmengen bei der Materialprüfung und Bauteilüberwachung an! Messdaten sind unsicher und verrauscht!*

- Einsatz von KI Methoden um eine grundlegende Abbildungsfunktion der experimentellen Wissenschaften abzuleiten und zu implementieren:

  $F($***Sensor Daten***$)$: ***Sensor Daten*** $\rightarrow$ ***Wissen***!
- Häufig existieren keine oder nur unvollständige numerische Material- und Bauteilmodelle
- **Inverse Numerik** kann eingesetzt werden um von Sensordaten auf Material- und Bauteileigenschaften zurück zuschließen ↠ *Meist zu komplex und rechenintensiv; Modelle müssen bekannt sein*!

2.3. Maschinelles Lernen

- Häufig fehlen funktionale Zusammenhänge zwischen zwei Variablen **x** und **y**, z.B., Dehnung einer Probe (Reactio) und wirkender äußerer Kraft (Actio, Stimulus):

  $f(\boldsymbol{x})$:$\boldsymbol{x} \rightarrow \boldsymbol{y}$.

- Neben der Bestimmung von **funktionalen Zusammenhängen** (*Materialprüfung*, *Lastüberwachung*) ist die **Zustandsvorhersage** zur Betriebszeit (*Strukturüberwachung*) wichtige Fragestellung.

Materialprüfung

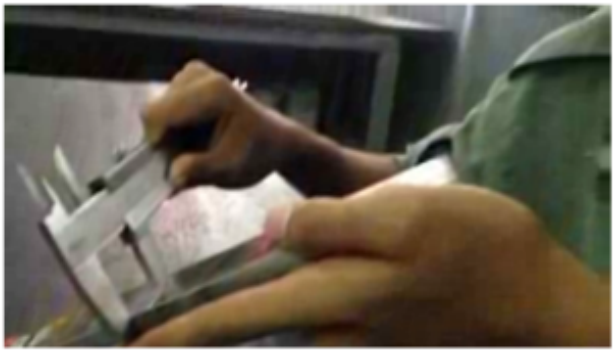

Strukturüberwachung

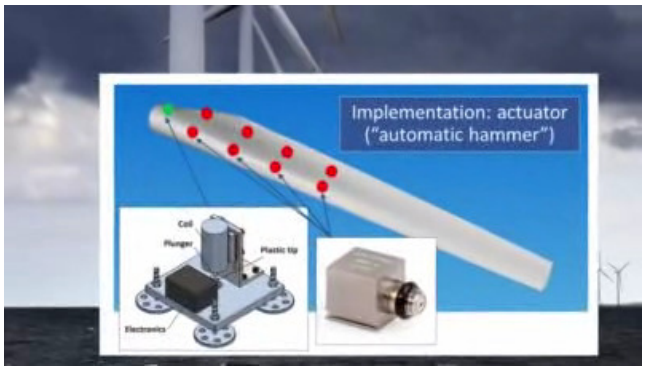

- Grundlegend wird beim Maschinellen Lernen auf Beobachtungen zurückgegriffen: Die **Trainingsdaten**
- Man unterscheidet zwei Arten des Maschinellen Lernens (ML):

Überwachtes Lernen

Die Trainingsdaten bestehen aus Eingabedaten ($\boldsymbol{x}$, Sensorvariablen, Strukturparameter, ..) mit den dazugehörigen Ausgabedaten ($\boldsymbol{y}$, sog. Labels, z.B. Materialparameter). Die Ausgabedaten werden i.A. von Experten (Menschen) zugeordnet, können aber auch durch eine automatische Bewertung rückgekoppelt werden (Verstärkungslernen).

Unüberwachtes Lernen

Beim sog. Clustering werden Muster in den Eingabedaten automatisch erkannt, d.h. die Trainingsdaten bestehen nur aus den Eingabedaten $\boldsymbol{x}$.

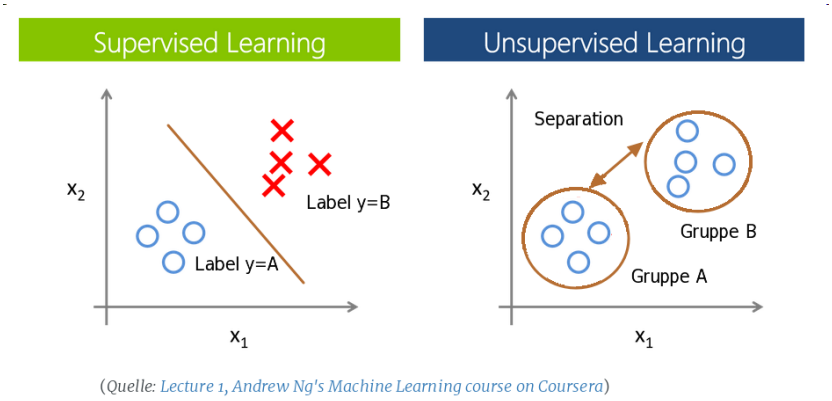

Abb. 1. Unterschied Überwachtes und nicht überwachtes Lernen

Mögliche Modelle für das vorherige Beispiel des Überwachten Lernens könnten sein:

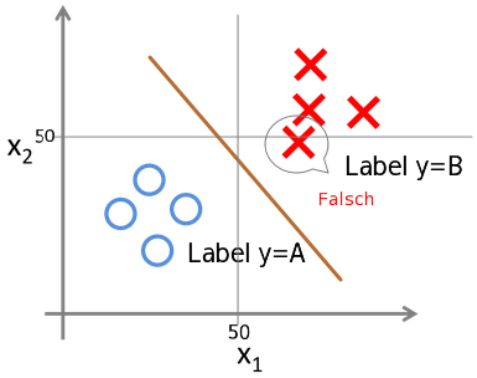

```
classify1(x1,x2): (x1,x2) → y =
  if (x2 < 50) then A
  else B

classify2(x1,x2): (x1,x2) → y =
  if (x1 < 50 and x2 < 50) then A
  else B
```

- Beim ML wird eine Approximation (Hypothese h) der unbekannten Klassifikations- und Vorhersagefunktion $f(\boldsymbol{x})$ berechnet: $\boldsymbol{y} = h(\boldsymbol{x}) = f(\boldsymbol{x}) + Err$.
- Es gibt eine Menge von Hypothesefunktionen $\boldsymbol{H}$ für ein Problem.
  - Beispiel *classify1* liefert für unteren roten Punkt falsches Ergebnis!

Rauschen

- Rauschen und Messunsicherheit können bis zur Unbrauchbarkeit das abgeleitete Modell beeinflussen!!!
- Das betrifft beiden Phasen:
  - Lernvorgang (Training)
  - Klassifikationsvorgang (Anwendung des gelernten Modells)
- Auch fehlerhafte Zuweisung von Labels (Klassen) ist Rauschen!
- **Einfluss von Rauschen abhängig vom verwendeten Algorithmus**

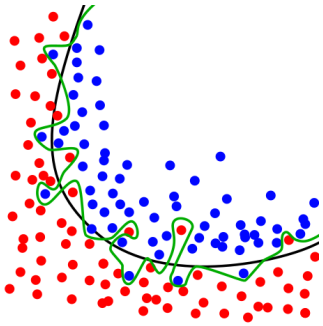

2.4. Maschinelles Lernen: Material und Struktur

Einsatz von ML in den Materialwissenschaften

Überwachtes Lernen	**Unüberwachtes Lernen**
Anwendungen: Vorhersage Struktur ⇆ Materialeigenschaften; Vorhersage von Schäden und Bauteilveränderungen; Kristallstrukturen klassifizieren	*Anwendungen:* Modellierung der Klassifikation von Schäden; Identifikation von Deskriptoren; Rauschunterdrückung in Messdaten
Methoden: Entscheidungsbäume; Support Vector Machines; Neuronale Netze; k Nearest Neighbour; Regularisierte Kleinste Quadrate	*Methoden:* Selbst-organisierende Karten (Neuronale Netze); k-Means Clustering; Markov Random Fields; Hierarchical Cluster Analysis; Principal Component Analysis; Cross-correlation

2.5. Maschinelles Lernen: SHM und Hybride/Composites

- Composite Strukturen und Hybride Materialien besitzen komplexe
  - Schädigungsmodelle,
  - Wellenausbeitungsmodelle, und
  - Meachanische Verhaltensmodelle.
- Vorhersage von Schäden und Bauteilveränderungen ist schwierig
- Z.B. Ausbreitung von Wellen als Messverfahren in Hybriden nicht vollständig bekannt!

2.6. Virtuelles Trainieren

- Verwendung von FEM und numerischen Methoden um Trainingsdaten für ML und Genetische Algorithmen zu erzeugen.
- Synthetisch generierte Messdaten können mit realen Messdaten kombiniert werden!

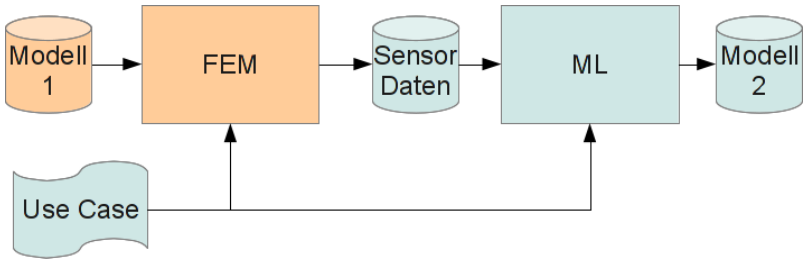

Abb. 2. Synthetisches Trainieren mit FEM

3. Algorithmen und Modelle

3.1. Modell: Entscheidungsbaum

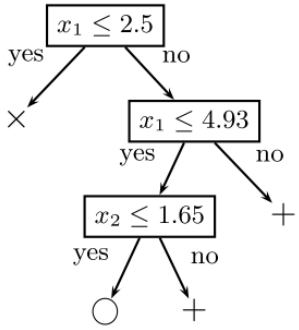

if $x_1 \leq 2.5$ then ×
if $x_1 \in (2.5, 4.93]$ and $x_2 \leq 1.65$ then ○
else +

- Ein Entscheidungsbaum besteht aus Knoten die mit einer bestimmten Eingangsvariable x_i verknüpft sind und diese evaluieren [3].
- Es gibt eine oder mehrere Kanten zu Nachfolgeknoten in Abhängigkeit vom Variablenwert (Relational oder Intervall).
- Blätter sind mit den Klassifikationsergebnis verknüpft.
- Sowohl Graphen-, Tabellen, als auch Programmnotation als Repräsentation des gelernten Modells verfügbar → **kompaktes Modell**!

3.2. Modell: Neuronales Netzwerk

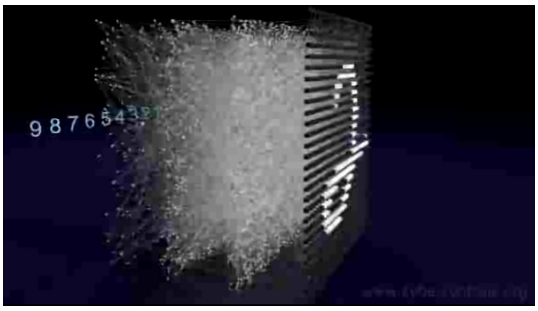

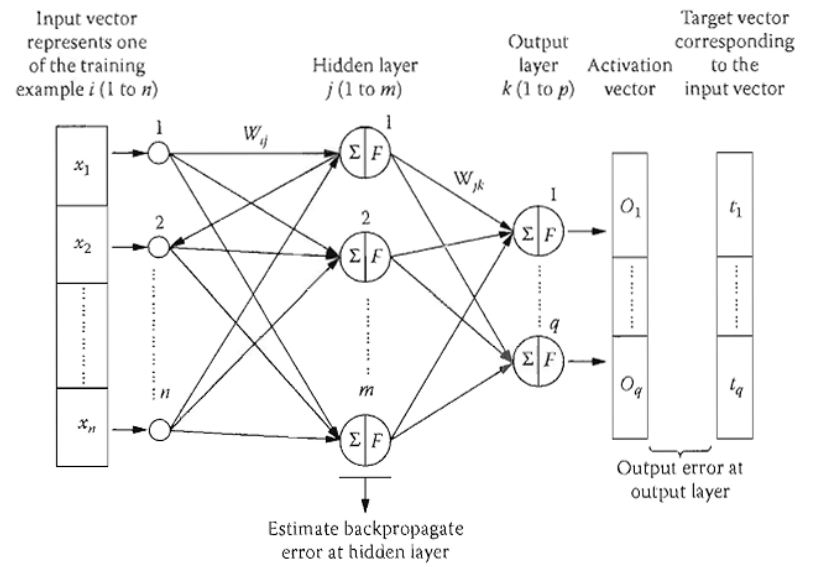

- Ein Künstliches Neuronales Netz (ANN) ist ein Netzwerk aus Neuronen (Perceptrons)[1].
- Jedes Neuron n_i hat ein oder mehrere Eingänge $\boldsymbol{x}_i$ und einen Ausgang y_i.
- Es gibt eine Aktivierungsfunktion: $f_i(\boldsymbol{x}_i)$: $\boldsymbol{x}_i \rightarrow y_i$, $y \in [0,1]$
- Das Trainieren des Netzwerkes ist iterativ (probalistisch) und erfolgt durch 1. Verteilung von Gewichten der Kanten; 2. Konfiguration, bis die gesamte Klassifikation mit minimalen Fehler möglich ist.

Beispiel: Einsatz eines ANN in der Schadensdetektion von Compositen [1]

Beispiele von Messsignalen einer Composite Probe

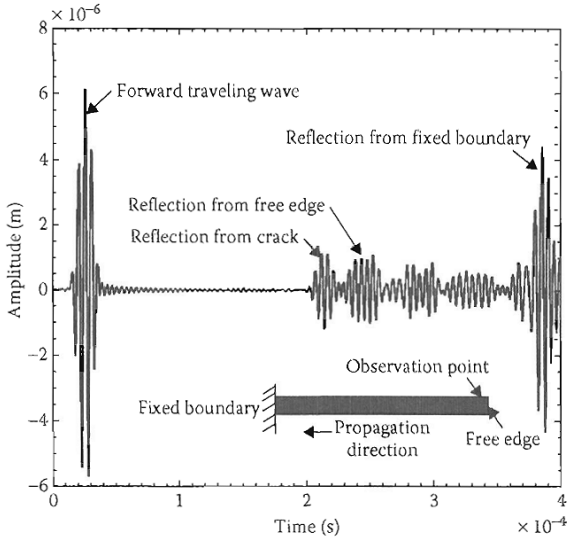

ANN: Eingangsvariablen sind ausgewählte Signalcharakteristka; Ausgangsvariablen sind Ort und Stärke einer Schädigung

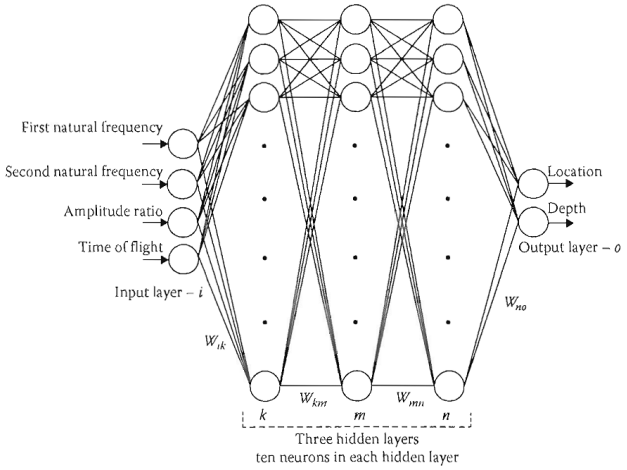

3.3. Agentenbasierte Verfahren

Agenten besitzen eine Vielzahl von Fähigkeiten, die sie von klassischen Programmen unterscheiden - obwohl Agenten auch Programme sind! ***Agent*** $\leftrightarrows$ ***Lernen***

Merkmale

- Fähigkeit zu eigenständiger Aktivität (*Nicht Nutzeraktiviert*)
- Autonomes Verhalten → ereignisbasiert (*Keine zentrale Intsanz*)
- Selbstständiges Schlussfolgern (*Umgang mit unsicheren Wissen*)
- Flexibles Verhalten (*Adaptivität an veränderliche Weltbedingungen*)
- Fähigkeit zu Kommunikation und Interaktion, Fähigkeit zur ziel- und aufgabenorientierten Koordination (*Synchronisation*)
- Kooperatives oder konkurrierendes Verhalten (*Lösung von Wettbewerbskonflikten*)
- **Divide&Conquer**: Dekomposition von komplexen Systemen

4. Anwendungsbeispiele

4.1. Modellierung von Composites mit ANN

- Ein Materialmodell welches auf einem Neuronalen Netzwerk basiert;
- Das Modell wird für den funktionalen Zusammenhang Spannung → Dehnung verwendet.

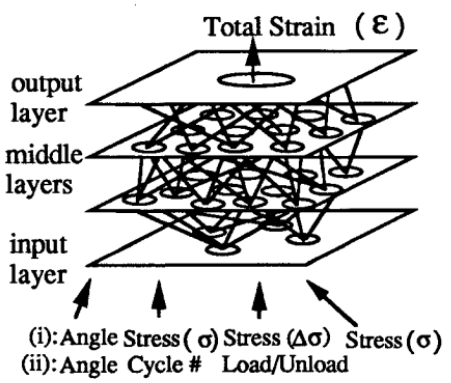

Pidaparti, 1992: Neuronales Netzwerk für monotone und zyklische Spannungs-Dehnungs Belastungen;

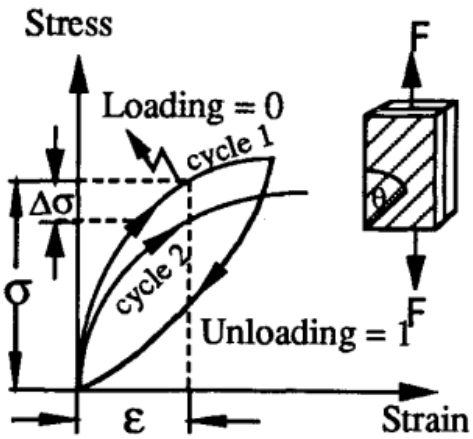

Verhaltensmodell des ANN [2]

4.2. Automatische Signalanalyse mit Agenten

- Region-of-Interest Erkennung von Ultraschallmesssignalen an Hybrid Proben mittels selbstorganisierenden Multiagentensystem (SoMAS) [4]
- Probleme bei Messsignalen und Auswertung: *Rauschen; Baseline; Dynamik; Nur ein kleines Zeitfenster beinhaltet relevante Struktur- und Schadensinformation; Reflexionen und Echos*

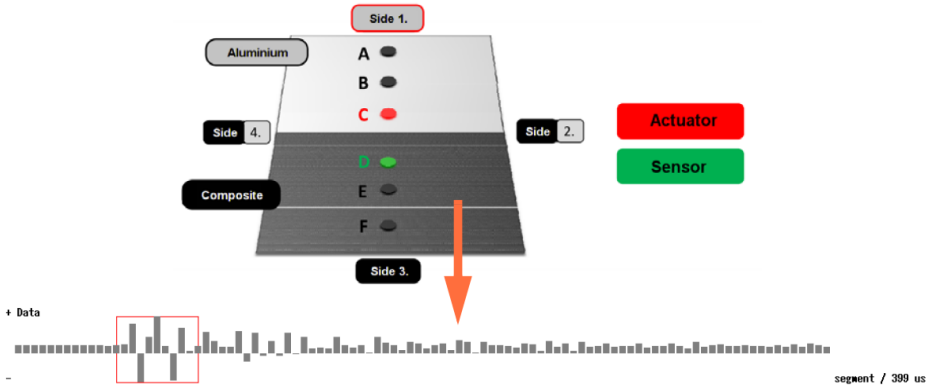

- Das Messsignal (50000 Punkte) wird auf 100 Segmente reduziert.
- Jedes Segment wird von einem Segmentagenten bearbeitet (Divide&Conquer)

- Explorationsagenten erkunden Nachbarschaft eines Segments nach Ähnlichkeit.
- Markierung von interessanten Segmenten → ROI Extraktion [5]

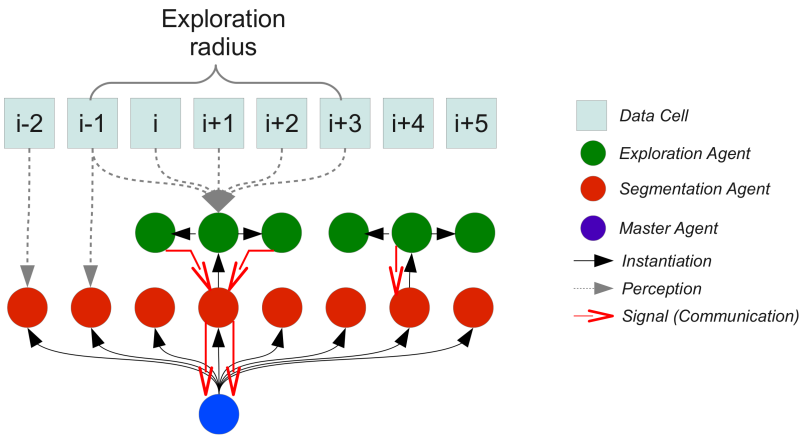

Kombination MAS mit ML

- Die Arbeitsweise des SoMAS wird durch einen Parametersatz $\boldsymbol{P}$ bestimmt.
- Signale mit deutlich unterschiedlichen Eigenschaften (Amplitude/Dynamik, Rauschen, Offset, Signalform) benötigen unterschiedliche Parameter.
- Ableitung eines geeigneten Parametersatzes $\boldsymbol{P}$ mit ML (ANN) aus Signaleigenschaften $\boldsymbol{sf}$ [4]:

$$h(\boldsymbol{sf}):\boldsymbol{sf} \rightarrow \boldsymbol{P},\ \boldsymbol{sf}=\{\boldsymbol{sc},\boldsymbol{hi},\boldsymbol{fi}\},$$
$$\boldsymbol{sc}=\{s_{\min},s_{\max},s_{\text{mean}},s_{\text{dev}}\},$$
$$\boldsymbol{hi}:\text{Histogram}^4,\ \boldsymbol{fi}:\text{FFT}^4.$$

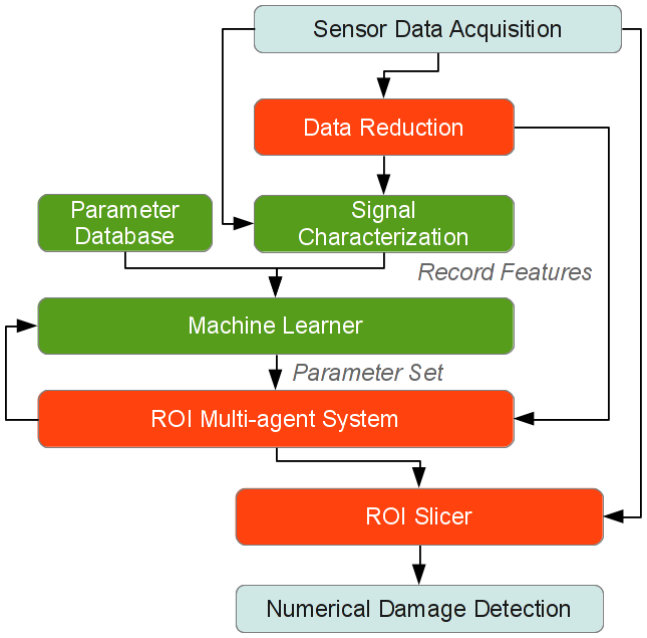

Mehr als 90% der ROIs von sehr unterschiedlichen Messsignalen können automatisch erkannt und direkt für die numerische Weiterverarbeitung zur Schadensdiagnostik verwendet werden.

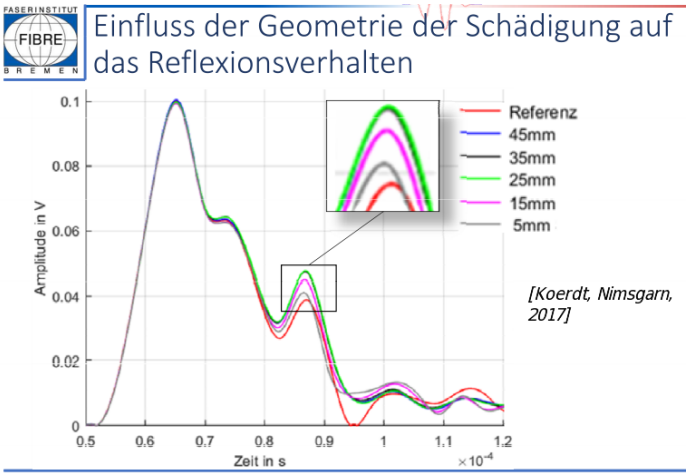

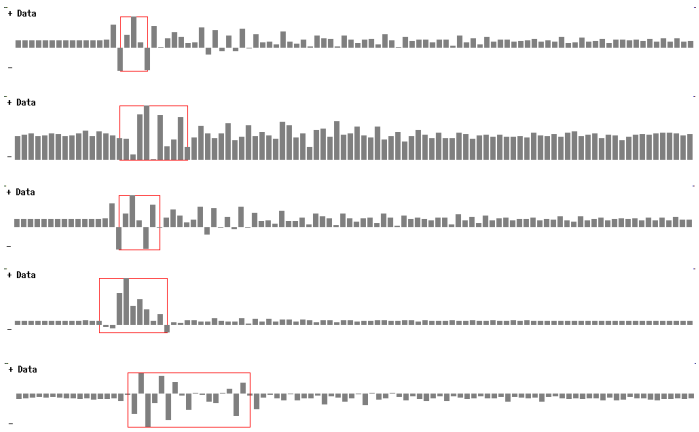

4.3. Ereignisbasierte Sensorverarbeitung mit Agenten

- Automatische und ereignisbasierte Erkennung von stimulierten Sensorbereichen in einem Sensornetzwerk mit SoMAS
- Gleiches Divde&Conquer Verfahren wie in der segmentierten ROI Erkennung mit **Explorationsagenten** (gelb).
- Sensorwerte aus stimulierten Bereichen (ROIs) werden durch **Verteilungsagenten** (grün) an Verarbeitungsagenten zugestellt.

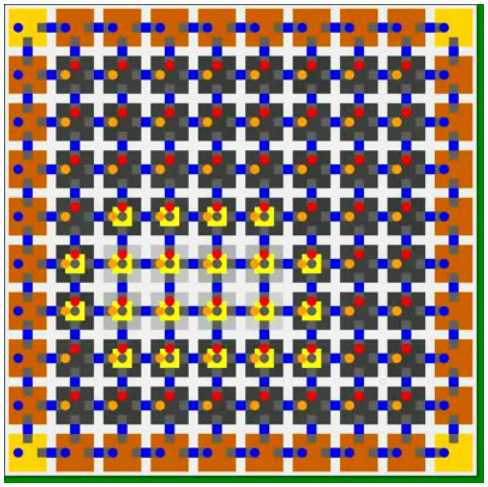

4.4. Lasterkennung mit Verteilten Lernen

- Beim SHM kommen i.A. große Sensornetzwerke zum Einsatz.

- Zentrale Signalverarbeitung nicht skalierbar und effizient;
- Daher Verteilung von Signalverarbeitung und Lernverfahren!

Ansatz: Viele verteilte Lerninstanzen die auf lokalen Daten arbeiten.

- Ereignisbasierte Signalverarbeitung und Lernen mit Agenten [6];
- Klassifikation liefert Vielzahl von Vorhersagen → Mehrheitsabstimmung als Schlussfolgerungsinstanz!

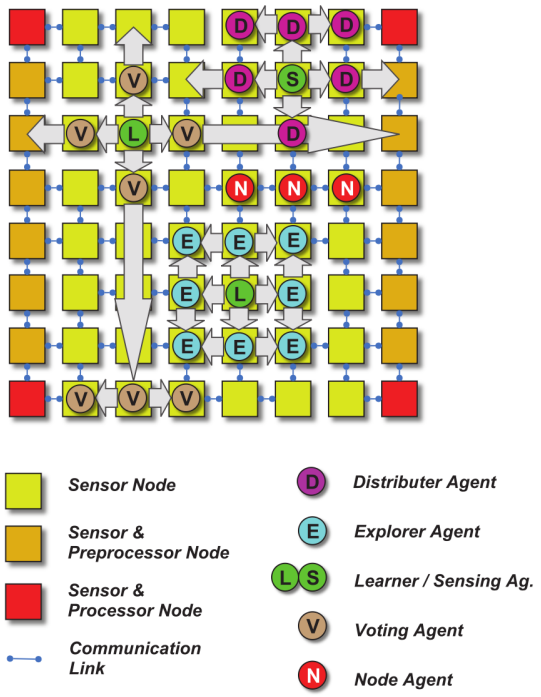

- Automatische Erkennung verschiedener Lastsituationen aus wenigen stimulierten Dehnungssensoren [6]:

Lastsituationen

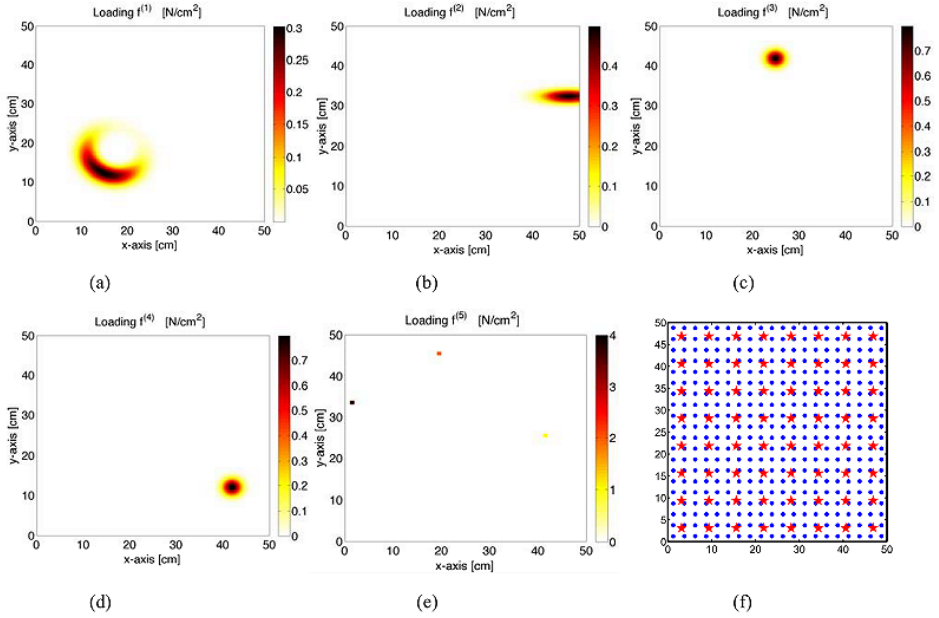

Beispiele für Wahlen

Votes[1]	**Election**
$n_{10,10}$:La, $n_{12,12}$:Lb, $n_{13,11}$:La, $n_{15,12}$:La,	La:3/4
$n_{44,32}$:Lb, $n_{47,33}$:Lc, $n_{50,32}$:Lb, $n_{45,28}$:Lc, $n_{43,32}$:Lb,	Lb:3/5

4.5. Strukturüberwachung von Verbundwerkstoffen

Ziel

Automatische Strukturüberwachung und Schadensdiagnostik ohne Struktur- und Materialmodelle

- Automatische Verarbeitung und Reduktion großer Datenmengen
  - Merkmalsselektion:Vorverarbeitung der Messdaten (Reduktion der Eingangsvariablen)

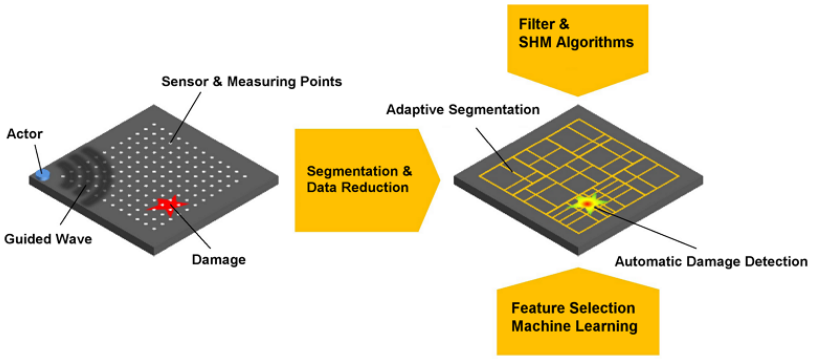

Abb. 3. Beispiel: 2D Luftultraschallscanning von beliebigen Proben [Schmidt, 2017]

  - Merkmalsextraktion:Schadensdiagnostik (Abbildung Eingangs- auf Ausgangsvariablen)Schadensklassifikation, Schdenslokalisation, Strukturveränderung, usw.

- Rückkopplung: Ergebnisse der Merkmalsselektion und Extraktion werden für Adaption des Messverfahrens verwendet.

5. Zusammenfassung

- Mit zunhemender Komplexität von Material- und Strukturmodellen wird **Schadensdiagnostik**, **Strukturüberwachung**, und **Materialentwicklung** schwieriger.
- Einsatz Hybrider Verfahren (z.B. MAS+ML)
- Es müssen große Datenmengen verarbeitet werden. Aber: Nur ein kleiner Teil der Eingangsdaten (Eingangsvariablen) ist relevant.
- Daher Dateneduktion → **Merkmalsselektion**
- KI Methoden können helfen relevante Informationen aus der großen wenig korrlierten Datenmenge zu extrahiern → **Merkmalsextraktion**
  - Maschinelles Lernen und Data Mining
  - Ungang mit unsicheren Wissen und Daten (Schliessen und Planen)
  - Agentenbasierte Verfahren
  - Verteilte und parallele Verfahren

6. Referenzen

Publikationen

1. R. Jha and S. V. Barai, *Neural Networks and Genetic Algorithms in Structural Health Monitoring*, in Structural Health Monitoring Technologies and Next-Generation Smart Composite Structures, J. A. Epaarachchi and G. C. Kahandawa, Eds. 2016.
2. R. M. V. Pidaparti and M. J. Palakal, *Material Model for Composites Using Neural Networks*, AIAA JOURNAL, vol. 31, no. 8, 1992.
3. I. Guyon, S. Gunn, M. Nikravesh, and L. A. Zadeh, *Feature Extraction: Foundations and Applications* (Studies in Fuzziness and Soft Computing). Springer, 2006.
4. S. Bosse, M. Koerdt, A. v. Hehl, *Robust and Adaptive Non Destructive Testing of Hybrids with Guided Waves and Learning Agents*, Hybrid 2018, Bremen
5. S. Bosse, D. Schmidt, M. Koerdt, *Robust and Adaptive Signal Segmentation for Structural Monitoring using Autonomous Agents*, ECSA 2017 (MDPI) , doi: 10.3390ecsa-4-04917
6. S. Bosse, A. Lechleiter, *A hybrid approach for Structural Monitoring with self-organizing multi-agent systems and inverse numerical methods in material-embedded sensor networks*, Mechatronics, (2016), DOI:10.1016 / j.mechatronics.2015.08.005.

Videos

A. Bending Test (Welding Inspector), www.youtube.com/watch?v=7tr4kVtNsrM

B. Structural health monitoring of wind turbine blade – Brüel & Kjær, www.youtube.com/watch?v=4Lo9-W3sVmE

C. Neural Network 3D Simulation, www.youtube.com/watch?v=3JQ3hYko51Y

D. S. Bosse, *From the Internet-of-Things to Sensor Clouds - Unified Distributed Computing in Heterogeneous Environments with Smart and Mobile Multi-Agent Systems*, Smart Systems Integration Conference, 11-12 March 2015, Copenhagen, 2015

Notes

[1]Knoten n bei Position (i,j)