

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

<b>1. Inhalt</b>	1
<b>2. Einführung</b>	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
<b>3. Algorithmen und Modelle</b>	7
3.1. Modell: Entscheidungsbaum . . . . .	7
3.2. Modell: Neuronales Netzwerk . . . . .	8
3.3. Agentenbasierte Verfahren . . . . .	10
<b>4. Anwendungsbeispiele</b>	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
<b>5. Zusammenfassung</b>	17
<b>6. Referenzen</b>	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:  
 *$F(\text{Sensor Daten}): \text{Sensor Daten} \rightarrow \text{Wissen!}$*
- 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):


$$f(x):x \rightarrow y.$$

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

#### *Materialprüfung*



#### *Strukturüberwachung*



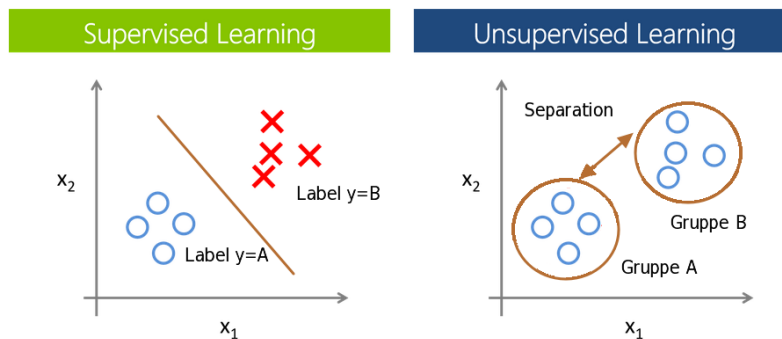
- Grundslegend wird beim Maschinellen Lernen auf Beobachtungen zurückgegriffen: Die **Trainingsdaten**
- Man unterscheidet zwei Arten des Maschinellen Lernens (ML):

### Überwachtes Lernen

Die Trainingsdaten bestehen aus Eingabedaten ( $\mathbf{x}$ , Sensorvariablen, Strukturparameter, ..) mit den dazugehörigen Ausgabedaten ( $\mathbf{y}$ , 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  $\mathbf{x}$ .




(Quelle: Lecture 1, Andrew Ng's Machine Learning course on Coursera)

---

**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 unbekanntes Klassifikations- und Vorhersagefunktion  $f(\mathbf{x})$  berechnet:  $\mathbf{y} = h(\mathbf{x}) = f(\mathbf{x}) + \text{Err}$ .
- Es gibt eine Menge von Hypothesefunktionen  $H$  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
<i>Anwendungen:</i> Vorhersage Struktur ⇔ Materialeigenschaften; Vorhersage von Schäden und Bauteilveränderungen; Kristallstrukturen klassifizieren	<i>Anwendungen:</i> Modellierung der Klassifikation von Schäden; Identifikation von Deskriptoren; Rauschunterdrückung in Messdaten
<i>Methoden:</i> Entscheidungsbäume; Support Vector Machines; Neuronale Netze; k Nearest Neighbour; Regularisierte Kleinste Quadrate	<i>Methoden:</i> 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,
  - Wellenausbreitungsmodelle, und
  - Mechanische 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!

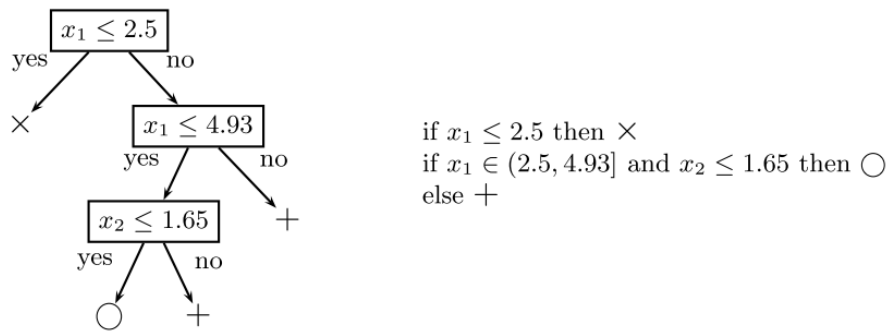


---

Abb. 2. Synthetisches Trainieren mit FEM

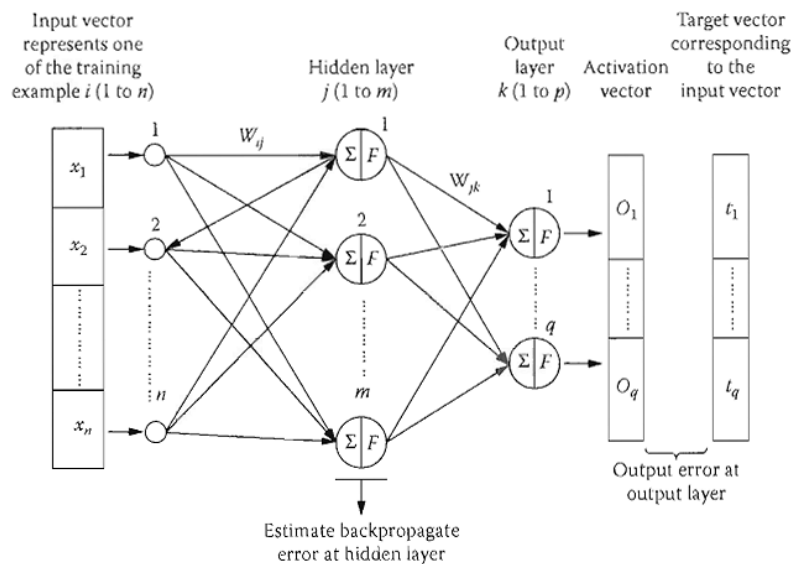

### 3. Algorithmen und Modelle

#### 3.1. Modell: Entscheidungsbaum



- 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!**

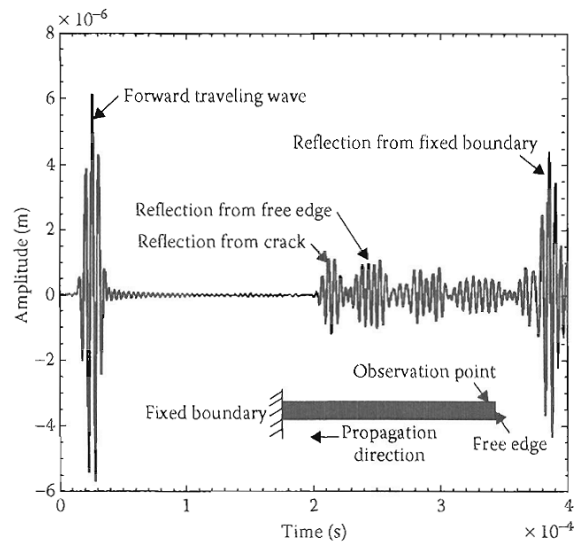
#### 3.2. Modell: Neuronales Netzwerk



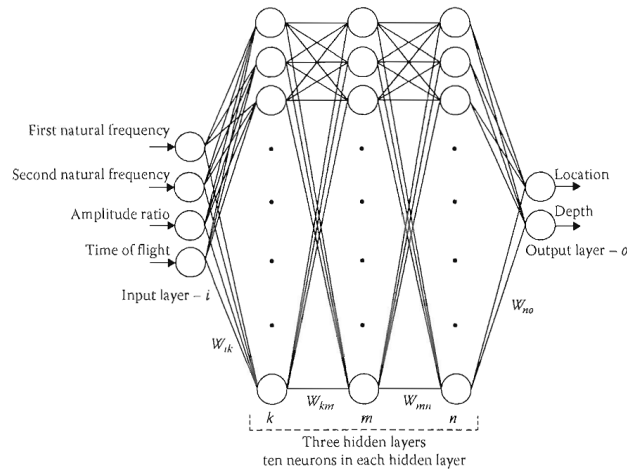
- Ein Künstliches Neuronales Netz (ANN) ist ein Netzwerk aus Neuronen (Perceptrons)[1].
- Jedes Neuron  $n_i$  hat ein oder mehrere Eingänge  $x_i$  und einen Ausgang  $y_i$ .
- Es gibt eine Aktivierungsfunktion:  $f_i(x_i): x_i \rightarrow y_i, y \in [0,1]$
- Das Trainieren des Netzwerkes ist iterativ (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 Signalcharakteristika; 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**  $\leftrightarrow$  **Lernen**


### **Merkmale**

- Fähigkeit zu eigenständiger Aktivität (*Nicht Nutzeraktiviert*)
- Autonomes Verhalten → ereignisbasiert (*Keine zentrale Instanz*)
- 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.



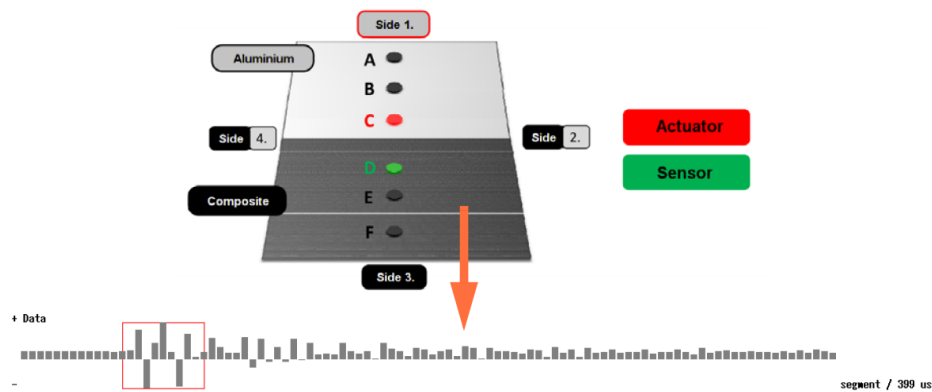
*Pidaparti, 1992: Neuronales Netzwerk für monotone und zyklische Spannungs-Dehnungs Belastungen;*



Verhaltensmodell des ANN [2]

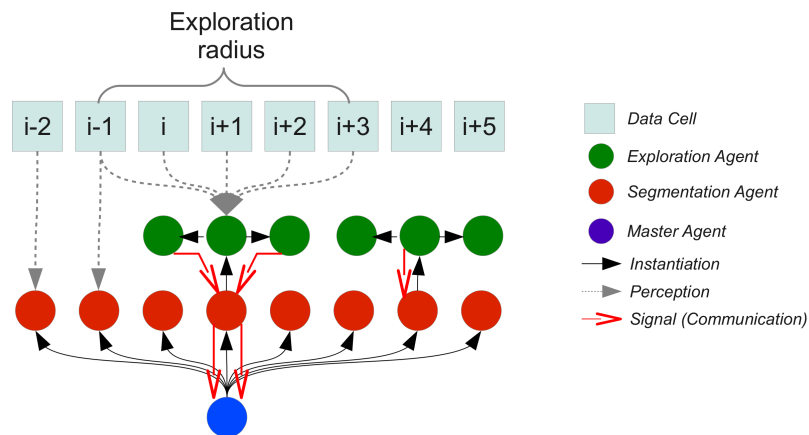
## 4.2. Automatische Signalanalyse mit Agenten

- 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)

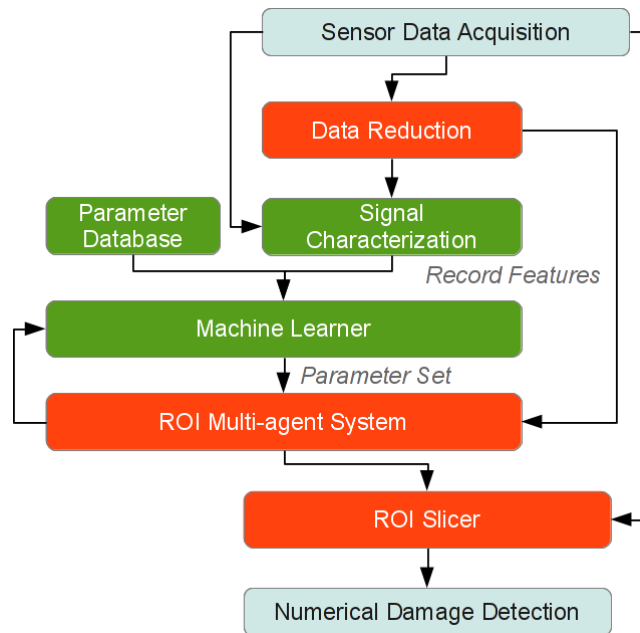
- Explorationsagenten erkunden Nachbarschaft eines Segments nach Ähnlichkeit.
- Markierung von interessanten Segmenten → ROI Extraktion [5]



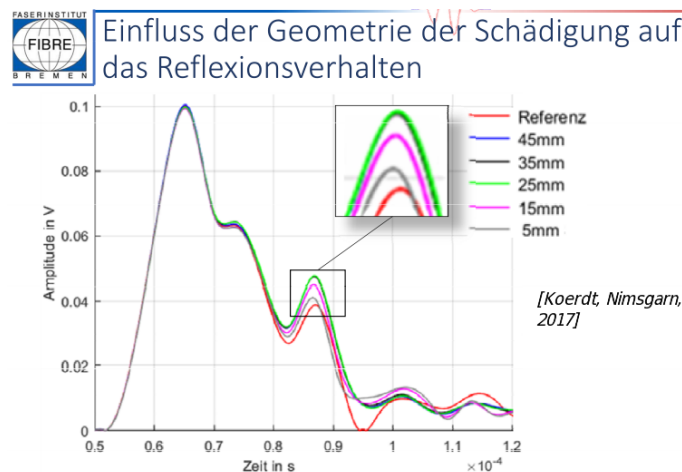
### Kombination MAS mit ML


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

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




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 Divide&Conquer Verfahren wie in der segmentierten ROI Erkennung mit **Explorationsagenten** (gelb).
- Sensorwerte aus stimulierten Bereichen (ROIs) werden durch **Verteilungsagenten** (grün) an Verarbeitungsagenten zugestellt.



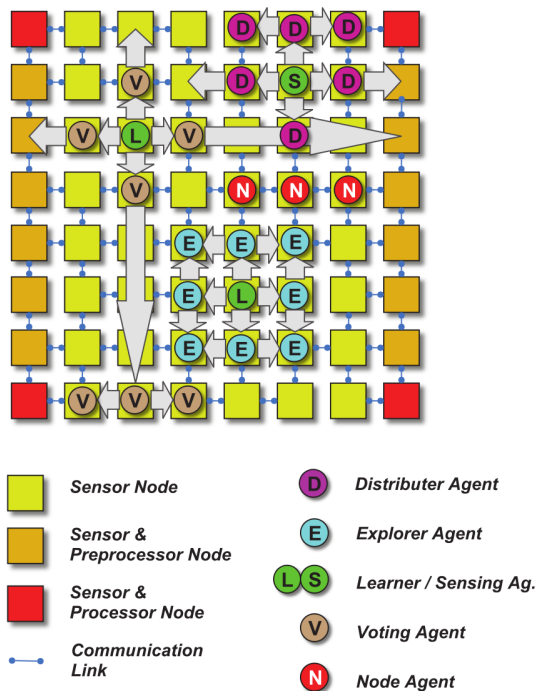
### 4.4. Lasterkennung mit Verteilten Lernen

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

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

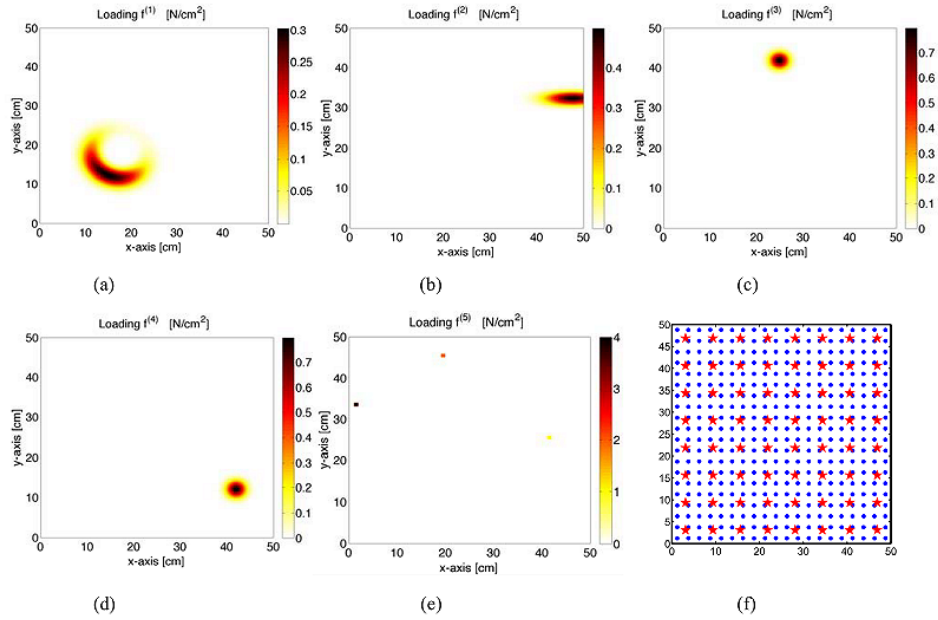
**Ansatz: Viele verteilte Lerninstanzen die auf lokalen Daten arbeiten.**

- 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

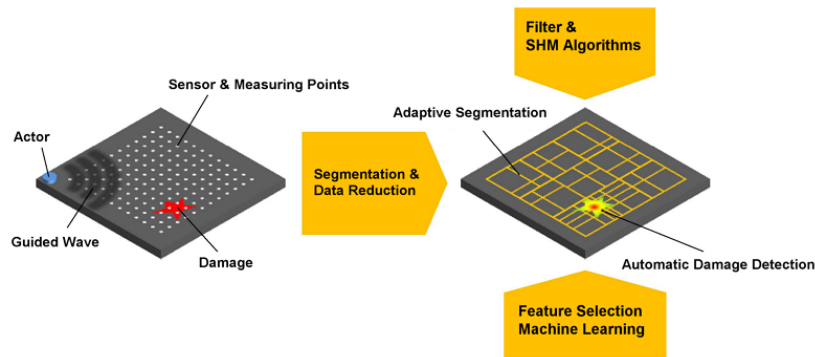
Votes <sup>1</sup>	Election
$n_{10,10}$ :La, $n_{12,12}$ :Lb, $n_{13,11}$ :La, $n_{15,12}$ :La,	La:3/4
$n_{44,32}$ :Lb, $n_{47,33}$ :Lc, $n_{50,32}$ :Lb, $n_{45,28}$ :Lc, $n_{43,32}$ :Lb,	Lb:3/5

## 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, Schadenslokalisierung, Strukturveränderung, usw.
- Rückkopplung: Ergebnisse der Merkmalsselektion und Extraktion werden für Adaption des Messverfahrens verwendet.

## 5. Zusammenfassung

- Mit zunehmender 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 korrelierten Datenmenge zu extrahieren → **Merkmalsextraktion**
  - Maschinelles Lernen und Data Mining
  - Umgang 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. Nikraves, 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: 10.3390/ecca-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](http://www.youtube.com/watch?v=7tr4kVtNsrM)
- B. Structural health monitoring of wind turbine blade – Brüel & Kjær, [www.youtube.com/watch?v=4Lo9-W3sVmE](http://www.youtube.com/watch?v=4Lo9-W3sVmE)
- C. Neural Network 3D Simulation, [www.youtube.com/watch?v=3JQ3hYko51Y](http://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

<sup>1</sup>Knoten n bei Position (i,j)