

Science becomes
reality





Deep Learning in der Praxis: Merkmalsbasierte Methoden und neuronale Netze für industrielle Anwendungen auf dem Prüfstand

Sandra Breitenberger und Kurt Pichler

Agenda

Vortrag
„Deep
Learning
in der
Praxis“

1. Einleitung
2. Vorstellung Team „Data Analytics & AI“
3. Merkmalsbasierte Ansätze
4. Neuronale Netze mit/ohne Transformation in den Bildbereich
5. Zusammenfassung



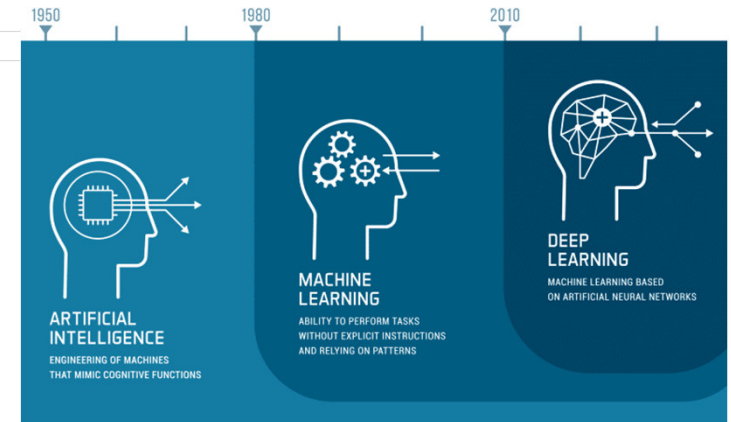
Einleitung

1

Einleitung

Was ist “Deep Learning”?

- Spezielle Methode der Informationsverarbeitung
- Teilgebiet des Forschungsfeldes des **maschinellen Lernens**
- Ziel: Funktionsweise des menschlichen Gehirns imitieren → Anwendung von neuronalen Netzen
 - Große Datenmengen (viele Erfahrungen) für das Training der KI
 - Bereits erlernte Fähigkeiten werden laufend mit neuen Inhalten angereichert und verknüpft
 - Maschine kann eigene Entscheidungen treffen und Prognosen erstellen
 - Unterstützung des Menschen bei der Arbeit
- Das Wort „deep“ oder „tief“ bezieht sich auf die verborgenen Schichten des entstandenen neuronalen Netzes.





Deep Learning (Quelle: https://www.volhighspeed.at/wp-content/uploads/2021/06/shutterstock_1628424196-1.png)

Einleitung

Klassisches Maschinelles Lernen vs Deep Learning

Maschinelles Lernen – merkmalsbasierter Ansatz	Deep Learning – Neuronale Netze
Manuelle Extraktion der relevanten Merkmale (Features)	Automatische Extraktion der relevanten Merkmale
Methode physikalisch erklärbar / Expertenwissen kann eingebracht werden	„Black-Box“ Funktion
Zeitaufwändiges „Engineering“ (geeignete Features generieren); Featureauswahl automatisierbar	Trainieren des Netzwerks benötigt viel Zeit, ist aber (halb) automatisierbar
Auch für kleinere Datenmengen	Ausreichend große Datenmengen nötig



ML vs DL (Quelle: <https://datasolut.com/wp-content/uploads/2020/03/machine-learning-vs-deep-learning-1024x819.jpg>)

Einleitung

Klassisches Maschinelles Lernen vs Deep Learning

Maschinelles Lernen – merkmalsbasierter Ansatz	Deep Learning – Neuronale Netze
Manuelle Extraktion der relevanten Merkmale (Features)	Automatische Extraktion der relevanten Merkmale
Methode physikalisch erklärbar / Expertenwissen kann eingebracht werden	„Black-Box“ Funktion
Zeitaufwändiges „Engineering“ (geeignete Features generieren); Featureauswahl automatisierbar	Trainieren des Netzwerks benötigt viel Zeit, ist aber (halb) automatisierbar
Auch für kleinere Datenmengen	Ausreichend große Datenmengen nötig




**AutoML (Automatisiertes
Maschinelles Lernen)!**

Einleitung

AutoML (Automatisiertes Maschinelles Lernen)

- Welche Schritte können automatisiert werden?
 - Datenvorverarbeitung
 - Feature Engineering
 - Parameteroptimierung
 - Modellauswahl
- Um diesem Ziel näher zu kommen → **LCM Feature Toolbox!**
- Vorteile des herkömmlichen Ansatzes können mit einem geringeren Zeitaufwand zur Algorithmusfindung kombiniert werden!



AutoML (Quelle: <https://media.istockphoto.com>)

Einleitung

Klassisches Maschinelles Lernen vs Deep Learning

Maschinelles Lernen – merkmalsbasierter Ansatz	Deep Learning – Neuronale Netze
Manuelle Extraktion der relevanten Merkmale (Features)	Automatische Extraktion der relevanten Merkmale
Methode physikalisch erklärbar / Expertenwissen kann eingebracht werden	„Black-Box“ Funktion
Zeitaufwändiges „Engineering“ (geeignete Features generieren); Featureauswahl automatisierbar	Trainieren des Netzwerks benötigt viel Zeit, ist aber (halb) automatisierbar
Auch für kleinere Datenmengen	Ausreichend große Datenmengen nötig



LCM Feature Toolbox!

Einleitung

Klassisches Maschinelles Lernen vs Deep Learning

Maschinelles Lernen – merkmalsbasierter Ansatz	Deep Learning – Neuronale Netze
Manuelle Extraktion der relevanten Merkmale (Features)	Automatische Extraktion der relevanten Merkmale
Methode physikalisch erklärbar / Expertenwissen kann eingebracht werden	„Black-Box“ Funktion
Zeitaufwändiges „Engineering“ (geeignete Features generieren); Featureauswahl automatisierbar	Trainieren des Netzwerks benötigt viel Zeit, ist aber (halb) automatisierbar
Auch für kleinere Datenmengen	Ausreichend große Datenmengen nötig

↓
LCM Feature Toolbox!

↓
Auswertungen mit/ohne Übergang
in den Bildbereich

Einleitung

Klassisches Maschinelles Lernen vs Deep Learning

Maschinelles Lernen – merkmalsbasierter Ansatz	Deep Learning – Neuronale Netze
Manuelle Extraktion der relevanten Merkmale (Features)	Automatische Extraktion der relevanten Merkmale
Methode physikalisch erklärbar / Expertenwissen kann eingebracht werden	„Black-Box“ Funktion
Zeitaufwändiges „Engineering“ (geeignete Features generieren); Featureauswahl automatisierbar	Trainieren des Netzwerks benötigt viel Zeit, ist aber (halb) automatisierbar
Auch für kleinere Datenmengen	Ausreichend große Datenmengen nötig

↓
LCM Feature Toolbox!

↓
LCM Transformation Toolbox!



Vorstellung Team „Data Analytics & AI“

2

Vorstellung Team “Data Analytics & Artificial Intelligence”

- Teil der Business Area “Sensors & Communication” des LCM
- Teamleiter: Veronika Putz und Valentin Sturm
- Insgesamt 10 Teammitglieder
- Entwicklung von lösungsorientierten Applikationen im Bereich Datenanalyse & datenbasierte KI



Vorstellung Team “Data Analytics & Artificial Intelligence”

- Anwendungen aus dem Gebiet der Objekterkennung, Mustererkennung, Zustandsüberwachung, Prädiktive Instandhaltung, Anomalie-Erkennung, Anlagenmodernisierung (Retrofitting), ...
 - Ausgangspunkt für Analysen sind immer Messdaten/Signale
 - Einsatz von Methoden aus der Signalverarbeitung, Bildverarbeitung, Datenanalyse, Statistik, Künstlichen Intelligenz
 - Implementierung auf Edge-Systemen mit geringer Rechenleistung





Merkmalsbasierte Ansätze

„Feature“-basierte Ansätze

Merkmalsbasierte Ansätze

“Feature“-basierte Ansätze

- **Feature Learning** = Klassisches Maschinelles Lernen
- Aus Merkmalen/Features werden Zusammenhänge abgeleitet
→ oft führt dies zu Klassifizierungs- oder Regressionsaufgaben
- **Regression**: es wird eine Regressionsfunktion gesucht, die den Zusammenhang von zwei oder mehreren Variablen optimal beschreibt
- **Klassifizierung**: Features/Datenpunkte werden zu verschiedenen Klassen zugeordnet
- In diesem Vortrag behandeln wir nur das Thema der Klassifizierung!


Merkmalsbasierte Ansätze

LCM Feature Toolbox

- Beinhaltet Features aus Zeitbereich, Frequenzbereich, Quefrenzbereich
- Mehr als 70 implementierte Features
- Automatische Auswahl der besten Features, um eine hohe Klassifizierungsgenauigkeit zu erzielen
- Verwendung der *Statistics & Machine Learning Toolbox* in Matlab sowie selbst implementierte Klassifizierungsmethoden (keine speziellen Matlab Toolboxen nötig)

Merkmalsbasierte Ansätze

Beispiel: Fehlererkennung in einer Entstaubungsanlage



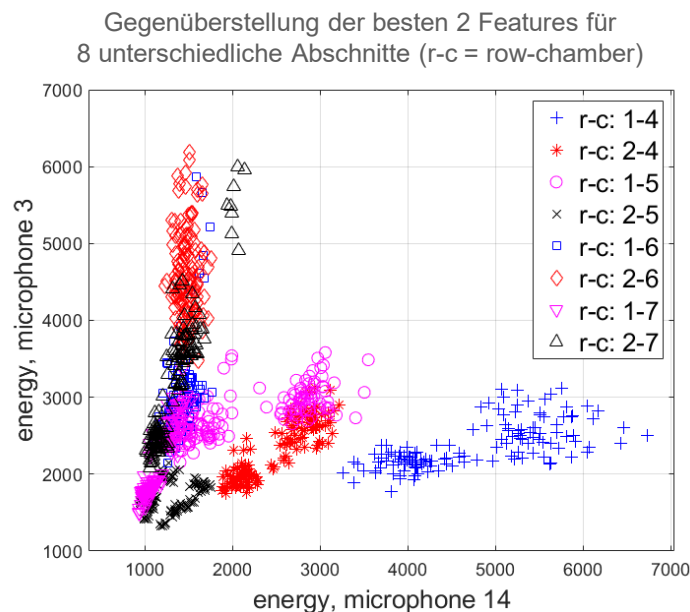
Anforderungen: Erkennen von fehlerhafter Aktivierung von Ventilen

- 280 Ventile (14 Abschnitte, davon 8 vermessen)
- Eine fehlerhafte Aktivierung eines Ventils soll durch Lokalisierung des Reinigungsgeräuschs erkannt werden.
- Lokalisierung anhand der Laufzeit ("akustische Kamera") kann aufgrund der Raumakustik (Ventile unter massiver Abdeckung, starker Nachhall) nicht verwendet werden.
- Messung mit 16 Mikrofonen an der Anlage; Daten innerhalb von 3 Stunden an der Anlage aufgezeichnet



Merkmalsbasierte Ansätze

Beispiel: Fehlererkennung in einer Entstaubungsanlage



- **Klassischer Ansatz** (pegelbasierte Lokalisierung) → **99.68%** der Geräusche können korrekt zugeordnet werden; Nachteil: Hardwareaufwand (16 Mikrofone erforderlich)
- Verbessertes **Ansatz mit Machine Learning** ermöglicht eine deutliche Reduktion des Hardwareaufwands:
 - Aus den Messdaten werden > 70 statistische Features für jedes Reinigungsgeräusch und jedes Mikrofon berechnet. Auswahl der 5 besten Features →
 - 99.53%** korrekt mit 16 Mikrofone
 - 98.90%** korrekt mit 8 Mikrofone
 - 95.96%** korrekt mit 4 Mikrofone

Klaffenböck, Maria Anneliese et al. "Feature-Based Acoustic Source Localization in a Pulse-Jet Bagfilter Plant." 2021 55th Asilomar Conference on Signals, Systems, and Computers (2021): 1398-1402.

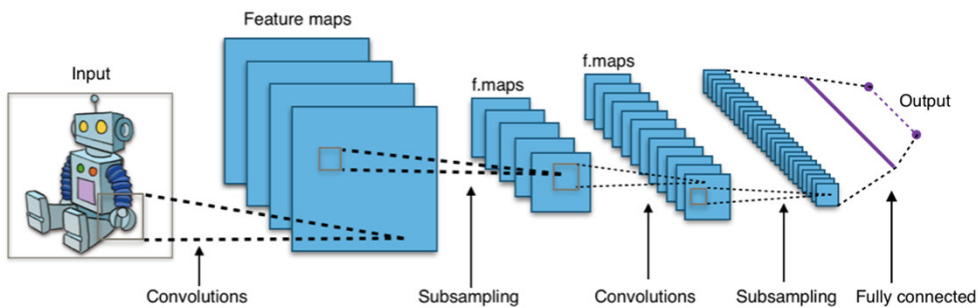


Neuronale Netze mit/ohne Transformation in den Bildbereich


Neuronale Netze mit/ohne Transformation in den Bildbereich

Überblick

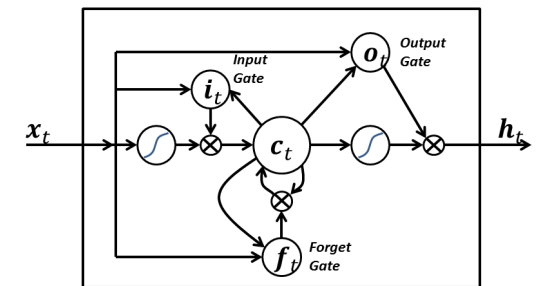
- Viele Typen von Neuronalen Netzen - hier wird eine Auswahl gezeigt
 - Fully Connected Neural Network (FCNN)
 - Long Short Term Memory (LSTM)
 - Convolutional Neural Network (CNN)
 - ...
- In der *Matlab Deep Learning Toolbox* verfügbar



CNN (Quelle: https://de.wikipedia.org/wiki/Convolutional_Neural_Network)



FCNN (Quelle: https://en.wikipedia.org/wiki/Artificial_neural_network)




LSTM Zelle (Quelle: https://de.wikipedia.org/wiki/Long_short-term_memory)

Neuronale Netze mit/ohne Transformation in den Bildbereich

Convolutional Neural Network (CNN)

- Input für **FCNN** und **LSTM** sind typischerweise (vorverarbeitete) Rohdaten bzw. Features
 - Für LSTM zeitliche Sequenzen von Daten
- Inputs für **CNN** sind typischerweise Bilder
- Vortrainierte CNNs verfügbar
 - AlexNet, InceptionNet, VGG, ResNet, EfficientNet,...
 - Vorteil des Transfer Learning ausnutzen (gelerntes Wissen zwischen verschiedenen Domänen transferieren)
 - Ist auch für Zeitreihenklassifizierung wünschenswert
- Umwandlung von Zeitreihen in Bilder
 - Verschiedene Methoden in der Literatur verfügbar




AlexNet Architektur (Quelle: A. Krizhevsky, I. Sutskever, and G. E. Hinton, *Imagenet classification with deep convolutional neural networks*, in Proceedings of the 25th International Conference on Neural Information Processing Systems, 2012)

Neuronale Netze mit/ohne Transformation in den Bildbereich


LCM Transformation Toolbox

- Methodenkatalog zur Umwandlung von Zeitreihen in Bilder in LCM-eigener Matlab Toolbox implementiert

- Iss2Image
- Signal Image
- Markov Transition Field
- Recurrence Plot
- ...



Signal Image



Markov Transition Field

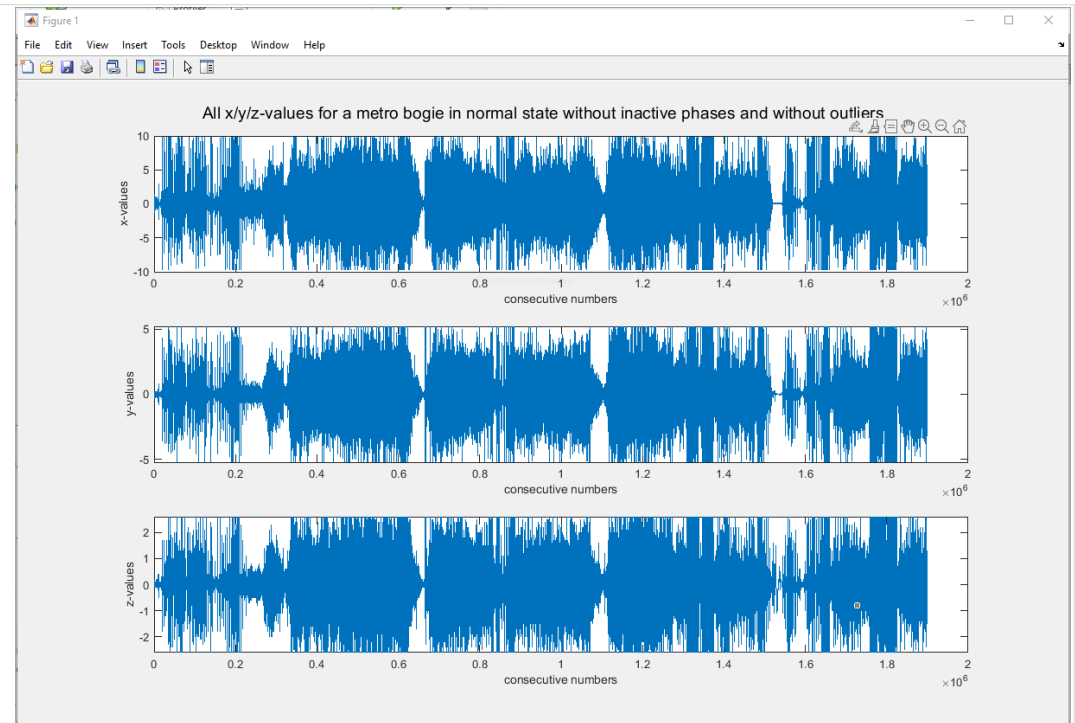
- Referenzen

- Z. Ahmad and N. Khan, *Inertial sensor data to image encoding for human action recognition*, IEEE Sensors Journal, vol. 21, no. 9, 2021
- K. Pichler, R. Haas, C. Kastl, A. Plöckinger, and P. Foschum, *Comparison of fault detection methods for a hydraulic accumulator loading circuit*, in IEEE Conference on Industrial Cyberphysical Systems (ICPS), 2020
- ...

Neuronale Netze mit/ohne Transformation in den Bildbereich

Beispiel: Metro-Daten

- Open Source Datensatz
 - <https://github.com/EnfangCui/MetroDataset>
 - Beschleunigungssensor an Fahrgestell einer U-Bahn
 - Klassen/Zustände: Normal bzw. Fehlerhaft
- Tests mit verschiedenen Methoden
 - Rohdaten als Input für FCNN
 - Rohdaten als Input für LSTM
 - Umwandlung in Bilder und Klassifizierung mittels CNN

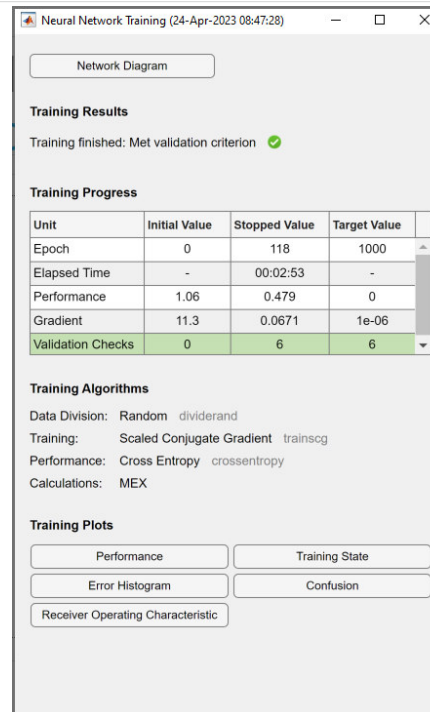


Neuronale Netze mit/ohne Transformation in den Bildbereich

Beispiel: Metro-Daten

- Resultate Neuronales Netz
 - Testgenauigkeit: 73.46 %
 - Trainingszeit: 237 Sekunden
 - Auswertzeit: 0.000046 Sekunden

```
net = patternnet([500, 300, 200, 100]);  
trained_net = train(net, input_train, label_train);  
predictions = trained_net(input_test);
```



Neuronale Netze mit/ohne Transformation in den Bildbereich

Beispiel: Metro-Daten


• Resultate LSTM

- Testgenauigkeit: 94.07 %
- Trainingszeit: 25.37 Stunden
- Auswertzeit: 0.0016 Sekunden

```
layers = [ ...  
    sequenceInputLayer(inputSize)  
    lstmLayer(neurons, OutputMode = "last")  
    fullyConnectedLayer(numClasses)  
    softmaxLayer  
    classificationLayer];
```

```
options = trainingOptions("adam", ...  
    ExecutionEnvironment="cpu", ...  
    GradientThreshold = 1, ...  
    MaxEpochs = epochs, ...  
    MiniBatchSize = mbs, ...  
    SequenceLength = seqLen, ...  
    Verbose = 0, ...  
    Plots = "training-progress");
```

```
trained_net = trainNetwork(input_train, label_train, layers, options);  
predictions = classify(trained_net, input_test);
```



Neuronale Netze mit/ohne Transformation in den Bildbereich


Beispiel: Metro-Daten

• Resultate CNN

```
% set parameters
miniBatchSize = 8;
valFrequency = floor(numel(augimdsTrain.Files)/miniBatchSize);
options = trainingOptions('sgdm', ...
    'MiniBatchSize', miniBatchSize, ...
    'MaxEpochs', 64, ...
    'InitialLearnRate', 3e-4, ...
    'Shuffle', 'every-epoch', ...
    'ValidationData', augimdsTest, ...
    'ValidationFrequency', valFrequency, ...
    'Verbose', false, ...
    'Plots', 'training-progress');
```

```
% train network
trained_net = trainNetwork(data_train, lgraph, options);
```


```
% predict
label_test = classify(trained_net, input_test);
```



Neuronale Netze mit/ohne Transformation in den Bildbereich

Beispiel: Metro-Daten

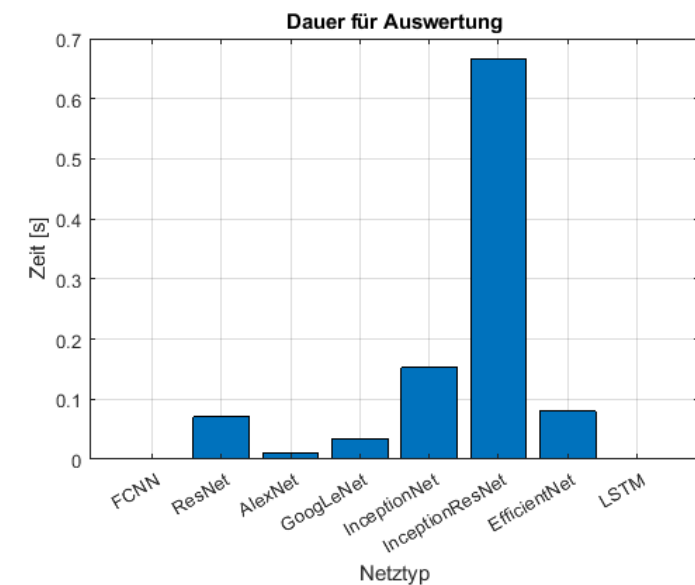

- Resultate CNN



Neuronale Netze mit/ohne Transformation in den Bildbereich

Beispiel: Metro-Daten


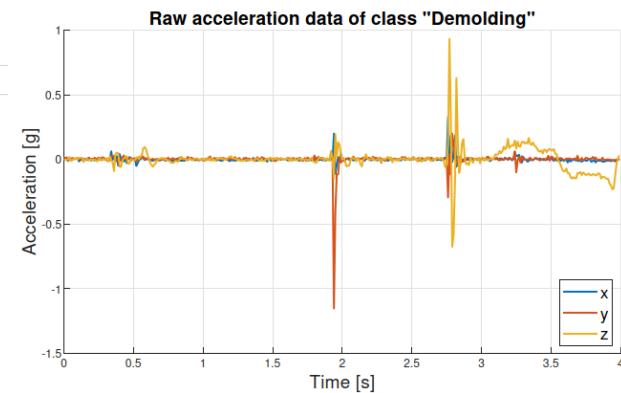
- Dauer für Training und Auswertung (Standard-Laptop)
 - FCNN jeweils sehr schnell
 - LSTM langsames Training, schnelle Auswertung
 - CNN dazwischen



Neuronale Netze mit/ohne Transformation in den Bildbereich

Beispiel: Daten Spritzgussmaschine

- Beispiel aus einem Firmenprojekt
 - Beschleunigungssensor auf Spritzgussmaschine
 - Erkennung der Phasen eines Spritzgusszyklus
 - Schließen, Plastifizieren, Entformen, Nichts
- Umwandlung der Signale in Bilder und anschließende Klassifikation mit CNNs
 - Testgenauigkeit ca. 94 %



→ CNN



Zusammenfassung

5

Zusammenfassung

- Viele Modelle für Machine Learning / Deep Learning in Matlab enthalten
- Ergänzt um LCM-eigene Toolboxen
 - Feature Toolbox
 - Transformation Toolbox
- Kein Patentrezept zur Auswahl der Methode bzw. des Modells
 - Für jeden Anwendungsfall individuelle Tests nötig

Linz Center of Mechatronics GmbH Altenberger Straße 69, 4040 Linz AUSTRIA
Sandra Breitenberger und Kurt Pichler, Senior Engineers Data Analytics & AI, sandra.breitenberger@lcm.at, kurt.pichler@lcm.at

A blurred background image showing two men in a meeting. One man on the left is wearing a light-colored sweater and glasses, and the other on the right is wearing a blue shirt. They appear to be looking at a whiteboard or screen.

Haben Sie noch
Fragen?

Bleiben wir in
Kontakt

Sandra Breitenberger und
Kurt Pichler

Senior Engineers Data Analytics & AI

sandra.breitenberger@lcm.at
kurt.pichler@lcm.at



Linz Center of Mechatronics GmbH, Altenberger Straße 69, 4040 Linz AUSTRIA



www.lcm.at



www.linkedin.com/company/linz-center-of-mechatronics



www.facebook.com/linzcenterofmechatronics