



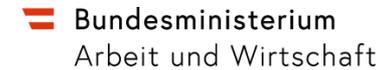
DIHOST

DIGITAL INNOVATION HUB

01

DIGITAL INNOVATION
HUB OST

PARTNER DES DIHOST



ABC RESEARCH

Austrian Blockchain Center





Digitalisierung auf den
Boden gebracht

DER **DIGITAL INNOVATION HUB OST** ALS WERKZEUG FÜR KMU

Unser Hub im Osten Österreich.
Ihre Brücke zur digitalen Innovation.

FOTEC – Geschäftsbereiche

Aerospace Engineering



© Daniel Hinterramskogler

- Ionenemitter
- Antriebssysteme
- Energiesysteme
- Test-Services

Innovative Software Systems



© FOTEC

- Forschungsfelder
- Auftragsentwicklung

Engineering Technologies



© Daniel Hinterramskogler

- Generative Fertigung

Business Engineering



© pixabay.com

- Produktdesign
- ML / Deep Learning
- Digitale Business Modelle
- Logistik
- Product Lifecycle Mgmt.

- Ablauf eines KI Projektes
- Overfitting / Datascience - Wopfinger Transportbeton GmbH.
- Muss es unbedingt KI sein? - Austria Pet Food GmbH.
- Falsche Erwartungen - TEST-FUCHS GmbH.
- Autoencoder / Transferlearning
- LLM – ChatGPT

Ablauf eines ML Projektes

Machine Learning (ML) - Ausdrücke

- ML: Supervised Learning, unsupervised Learning, Reinforcement Learning, Clustering, Decision Trees, Classification, Regression, Autoencoder
- Deep Learning: Deep Neural Network (DNN), Convolutional Network (CNN), Recurrent Neuronal Network (RNN), Generative Adversarial Networks (GAN)
- Auto ML

Fähigkeiten / Voraussetzungen

Deskriptive Statistik, Explorative Statistik, Wahrscheinlichkeitstheorie, Induktive Statistik, Clusterverfahren, Ähnlichkeitsverfahren, mathematische Algorithmen, Datenbanken, Datenkonvertierung, Matrizenrechnung, Programmierskills

Ablauf eines ML Projektes

Die technische Evaluierung Plattformen fällt ziemlich homogen aus. Jeder Plattform hat Vor- und Nachteile, wodurch keine klare Aussage möglich ist. Folgende Grundaussagen treffen mit Sicherheit zu.

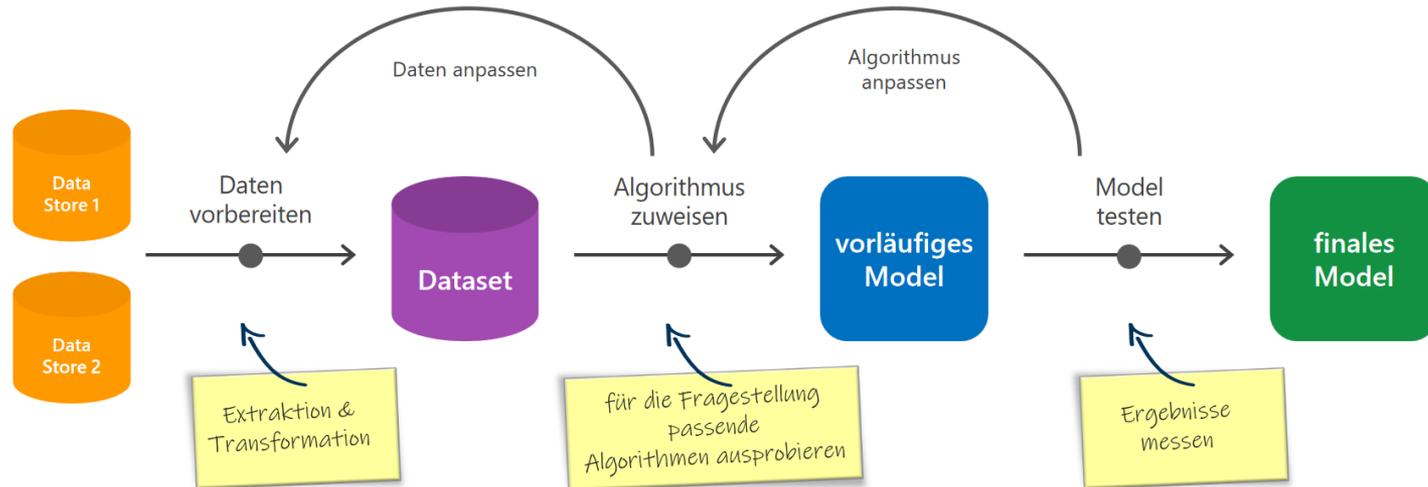
MATLAB

- wenn man schnell ans Ziel kommen will
- wenn ONNX Files in anderen Systemen verwendet werden können

PYTHON

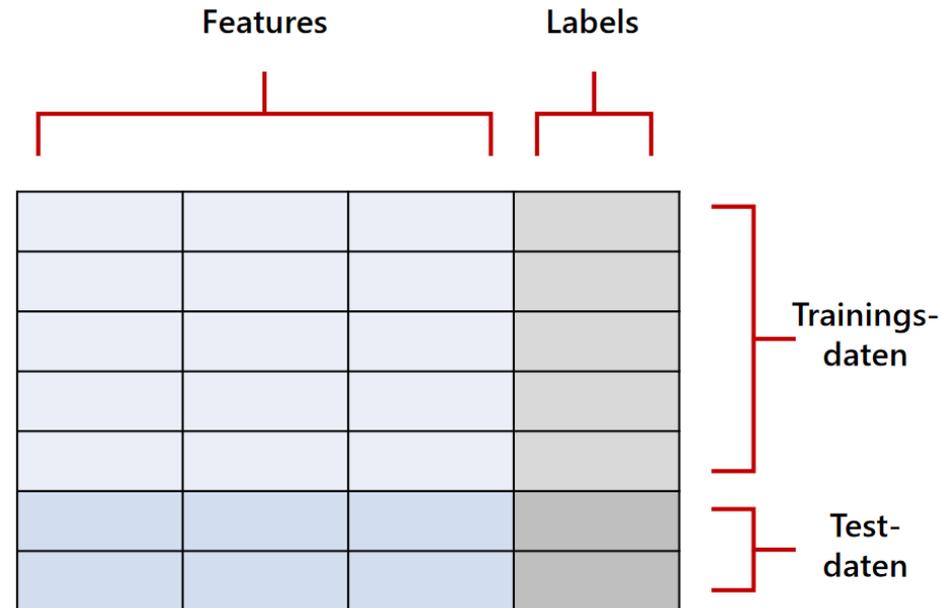
- wenn man tief einsteigen will und Personalressourcen vorhanden sind
- wenn die Community eine Rolle spielt
- wenn man damit nicht in Produktionsumgebungen gehen will

Ablauf eines ML Projektes

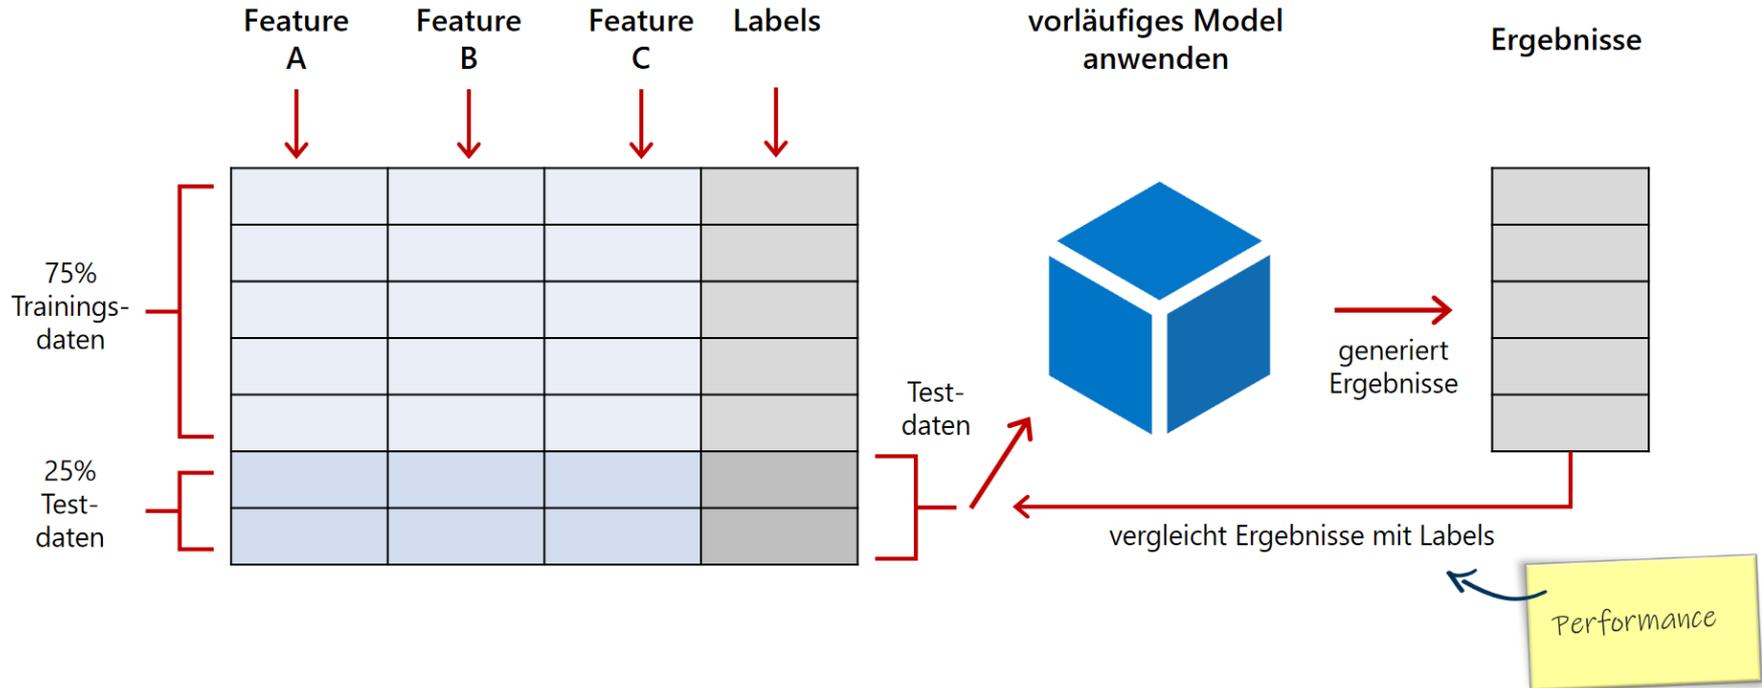


Ablauf eines ML Projektes

- Wie müssen Daten aussehen?
 - Relevanz
Habe ich die richtigen Daten um eine Vorhersage treffen zu können?
 - Vollständigkeit
Haben alle Spalten meines Datasets Werte?
 - Qualität
Sind die Werte realistisch und decken Sie die Skala an Möglichkeiten ab?
 - Menge
Habe ich genügend Daten um sichere Vorhersagen treffen zu können?



TESTING



Ablauf eines ML Projektes

Was sollte bei einem ML Projekt beachtet werden?

- Kein Zugriff auf Geräteinformationen
Was soll überwacht werden? Interne Produktionsmaschinen oder Geräte die Sie produzieren?
- Interne IT Richtlinien verhindern Vieles!
Suchen Sie bei Umsetzung nach der Unterstützung Ihres CEOs!
- Bei Sensor Erweiterung einer Produktionsanlage: Ist eine Maschine eingeschalten?
Keine Daten sammeln, wenn die Maschine nicht produziert!
- Keine, unzureichende oder nicht klassifizierte Daten vorhanden
- Deklarieren Sie das ML Projekt als Forschungsprojekt

Überblick Machine Learning

Deep Learning = Teilbereich aus ML, funktioniert jedoch komplett unterschiedlich

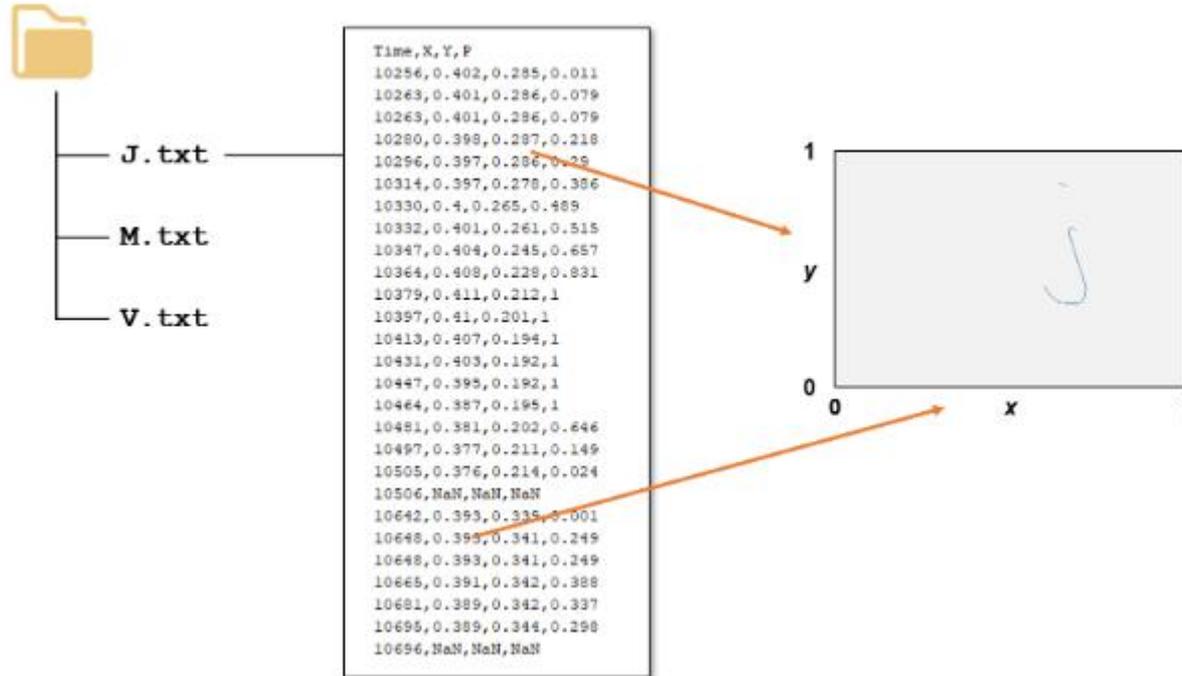
Machine Learning

- Wenige Datensätze notwendig (~500)
- Domänenwissen notwendig
- Keine speziellen Hardwareanforderungen
- Ergebnisse nachvollziehbar

Deep Learning

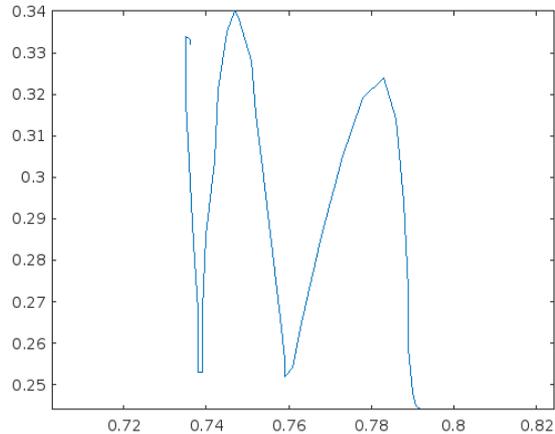
- Viele Datensätze notwendig (>5000)
- Geringes Domänenwissen notwendig
- Teure Hardware (viel Speicher, GPU!)
- Ergebnisse nicht nachvollziehbar

Machine Learning - Buchstabenerkennung

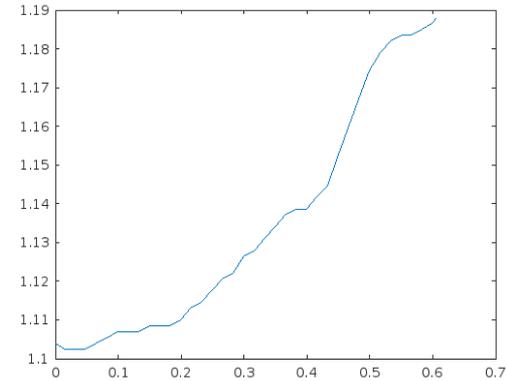


Machine Learning - Buchstabenerkennung

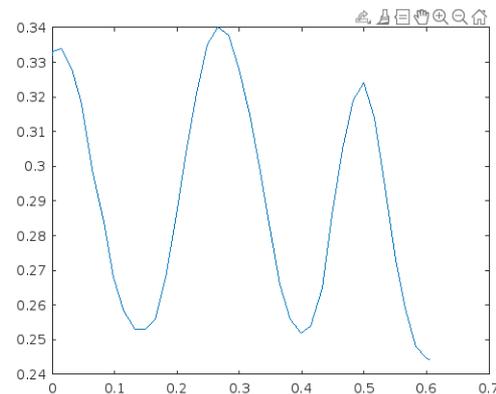
Zeitliche Betrachtung der Daten auf X und Y-Koordinaten



Welche Merkmale könnten genutzt werden?



X-Achse



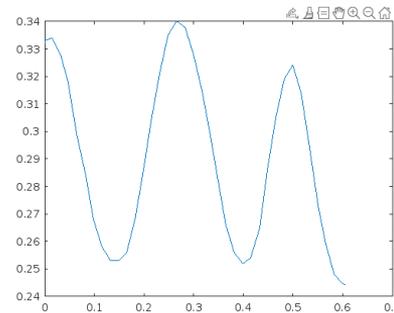
Y-Achse

Machine Learning - Buchstabenerkennung

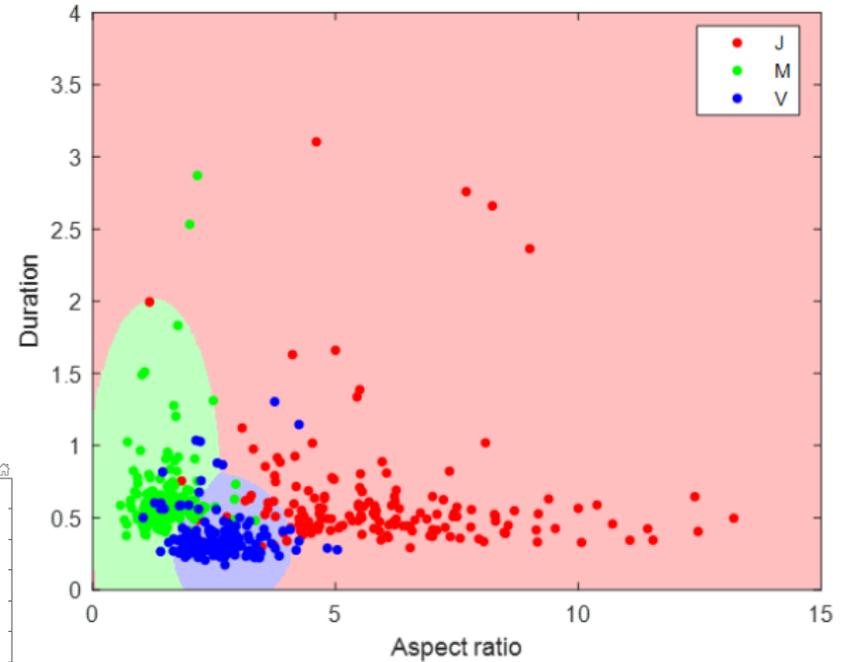
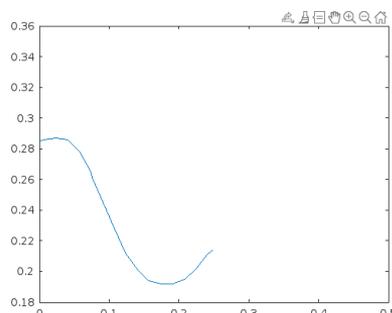
Welche Merkmale könnten genutzt werden?

- Dauer
- X/Y Verhältnis
- Extremstellen

M: Y-Achse



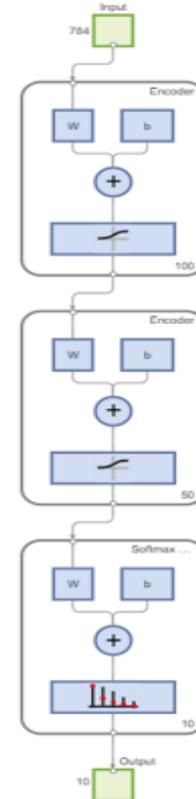
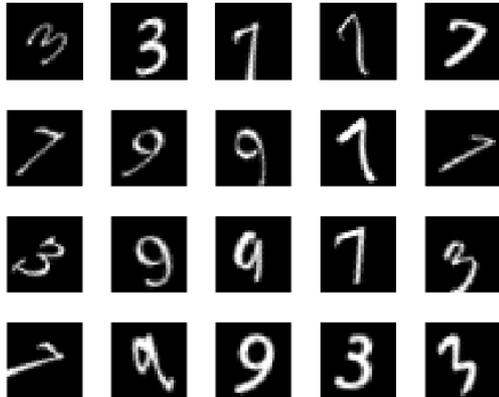
J: Y-Achse



Deep Learning - Zahlenerkennung

Deep Learning

- Ziffern von 0-9
- 5000 Bilder pro Ziffer
- Stacked Autoencoder



Deep Learning - Zahlenerkennung

Confusion Matrix

Output Class \ Target Class	1	2	3	4	5	6	7	8	9	10	Accuracy
1	485 9.7%	0 0.0%	0 0.0%	1 0.0%	0 0.0%	0 0.0%	3 0.1%	0 0.0%	0 0.0%	0 0.0%	99.2% 0.8%
2	6 0.1%	492 9.8%	1 0.0%	0 0.0%	0 0.0%	0 0.0%	6 0.1%	1 0.0%	1 0.0%	1 0.0%	96.9% 3.1%
3	0 0.0%	5 0.1%	490 9.8%	0 0.0%	5 0.1%	0 0.0%	0 0.0%	2 0.0%	0 0.0%	1 0.0%	97.4% 2.6%
4	0 0.0%	0 0.0%	3 0.1%	495 9.9%	0 0.0%	1 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	99.2% 0.8%
5	7 0.1%	0 0.0%	2 0.0%	0 0.0%	494 9.9%	1 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	98.0% 2.0%
6	0 0.0%	1 0.0%	0 0.0%	3 0.1%	1 0.0%	498 10.0%	0 0.0%	0 0.0%	0 0.0%	2 0.0%	98.6% 1.4%
7	1 0.0%	1 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	489 9.8%	0 0.0%	1 0.0%	1 0.0%	99.2% 0.8%
8	1 0.0%	0 0.0%	3 0.1%	1 0.0%	0 0.0%	0 0.0%	0 0.0%	497 9.9%	0 0.0%	0 0.0%	99.0% 1.0%
9	0 0.0%	0 0.0%	1 0.0%	0 0.0%	0 0.0%	0 0.0%	2 0.0%	0 0.0%	498 10.0%	1 0.0%	99.2% 0.8%
10	0 0.0%	1 0.0%	0 0.0%	494 9.9%	99.8% 0.2%						
	97.0% 3.0%	98.4% 1.6%	98.0% 2.0%	99.0% 1.0%	98.8% 1.2%	99.6% 0.4%	97.8% 2.2%	99.4% 0.6%	99.6% 0.4%	98.8% 1.2%	98.6% 1.4%

```

% Train
[xTrainImages,tTrain] = digitTrainCellArrayData;

hiddenSize1 = 100;
autoenc1 = trainAutoencoder(xTrainImages,hiddenSize1, ...
    'MaxEpochs',400, ...
    'L2WeightRegularization',0.004, ...
    'SparsityRegularization',4, ...
    'SparsityProportion',0.15, ...
    'UseGPU', true, ...
    'ScaleData', false);

softnet = trainSoftmaxLayer(feats2,tTrain,'MaxEpochs',400);
stackednet = stack(autoenc1,softnet);

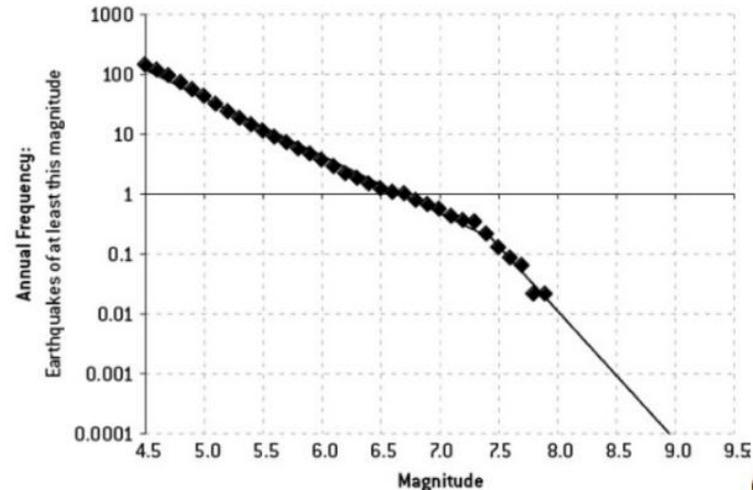
% Test
[xTestImages,tTest] = digitTestCellArrayData;
y = stackednet(xTest);
plotconfusion(tTest,y);
    
```

- Overfitting / Datascience
Wopfinger Transportbeton GmbH.
- Muss es unbedingt KI sein?
Austria Pet Food GmbH.
- Falsche Erwartungen
TEST-FUCHS GmbH.
- Autoencoder / Transferlearning

Overfitting – Fukushima Disaster

Bei der Planung des Kraftwerks mussten die Ingenieure ermitteln, wie häufig Erdbeben auftreten würden. Sie nutzten ein bekanntes Gesetz, das so genannte Gutenberg-Richter-Gesetz, mit dem sich die Wahrscheinlichkeit eines sehr starken Erdbebens anhand der Häufigkeit sehr schwacher Erdbeben vorhersagen lässt.

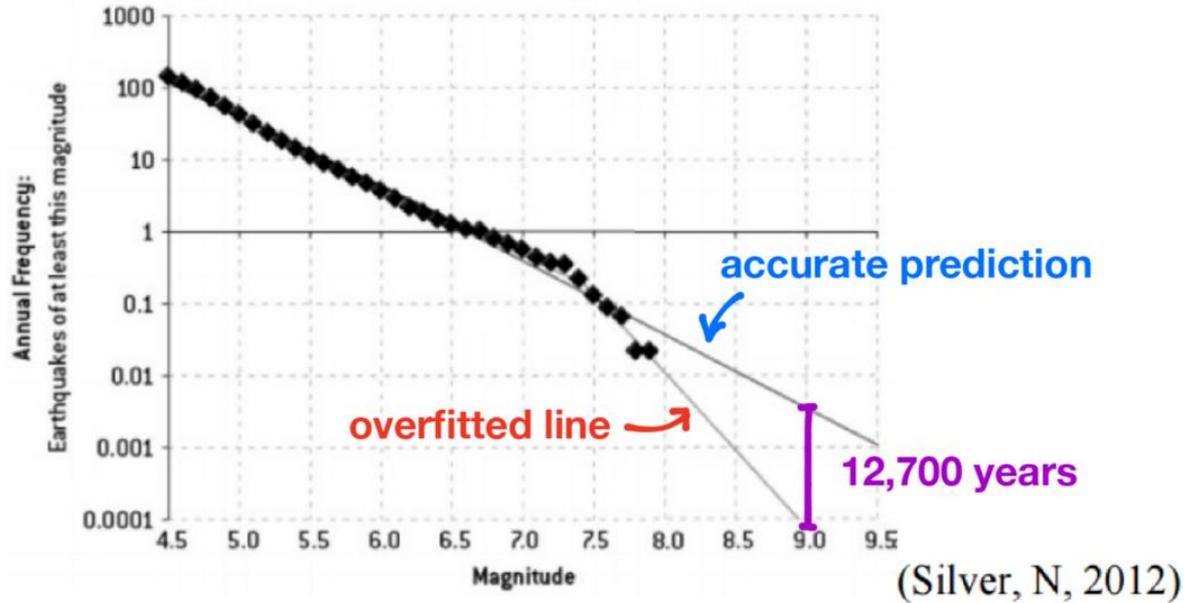
FIGURE 5-7C: TŌHOKU, JAPAN EARTHQUAKE FREQUENCIES
CHARACTERISTIC FIT



(Silver, N, 2012)

Overfitting – Fukushima Desaster

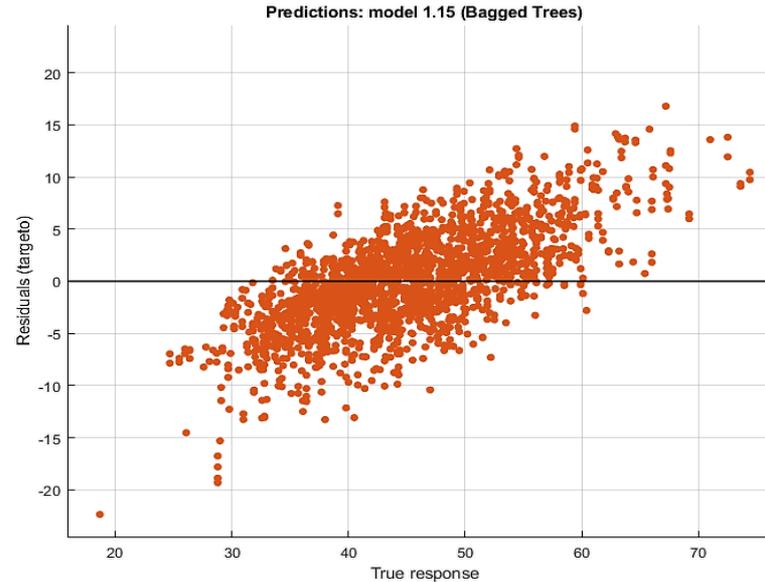
FIGURE 5-7C: TŌHOKU, JAPAN EARTHQUAKE FREQUENCIES
CHARACTERISTIC FIT



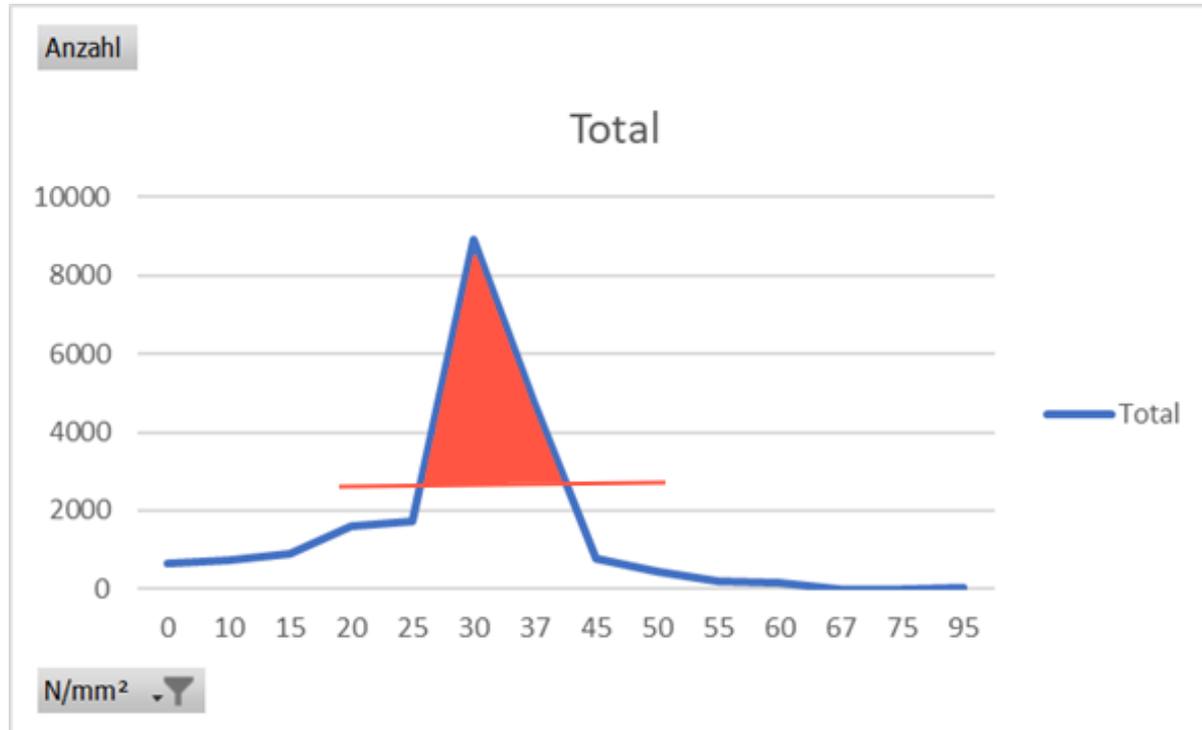
Overfitting – Wopfinger Transport Beton

- Laufzeit: 2 Jahre
- Rezepturen: 20741
- Parameter: 329

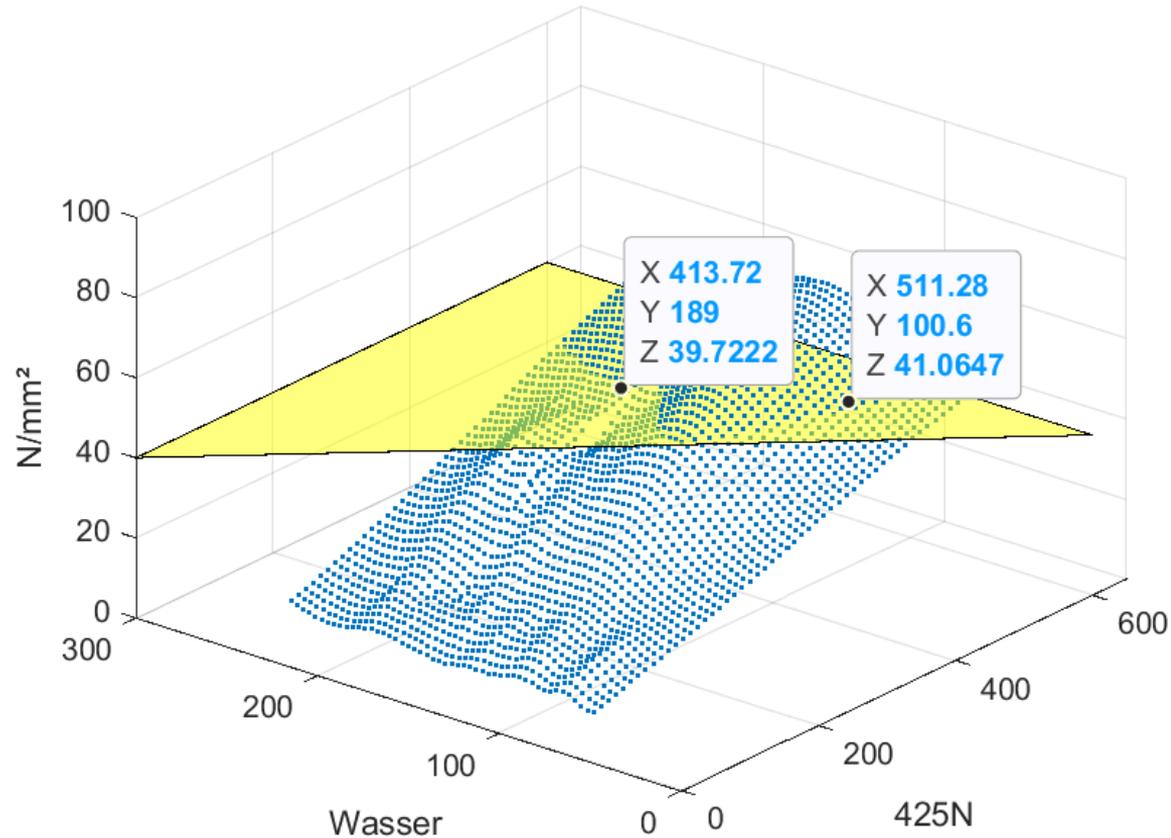
Ziel: Berechnung der
Druckfestigkeit anhand von
Betonrezepturen
Soll-Genauigkeit von $\leq 10\%$



Overfitting – Wopfinger Transport Beton



Overfitting – Wopfinger Transport Beton



DIH-Ost

- Muss es unbedingt KI sein?
Austria Pet Food GmbH.
- Falsche Erwartungen
TEST-FUCHS GmbH.
- Autoencoder / Transferlearning
- ChatGPT

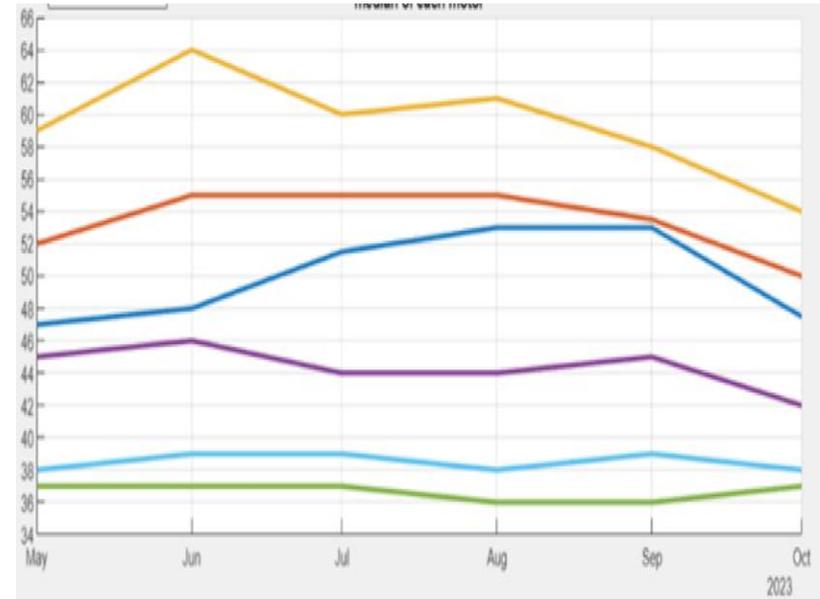
Muss es immer KI sein? – Austria Pet Food

Überwachung von Förderbändern

- Frequenzmessung / Körperschall
- Messung von Vibrationen
- Anbringung zusätzlicher Sensoren
- Korrosionsproblem wegen Reinigungszyklen und Mittel

Stattdessen

- Indirekte Überwachung
- Stromverbrauch der E-Motoren
- Rein statistischer Ansatz
- Kosten ca. €7.000,-



- Falsche Erwartungen
TEST-FUCHS GmbH.
- Autoencoder / Transferlearning
- LLM – ChatGPT

Falsche Erwartungen, aber positives Ergebnis – TEST-FUCHS

Ressourcen

- ~2000 Mannstunden
- ~€300.000,-
- 2 Jahre Laufzeit

Projektziele

- Sensorik Erweiterung
- Ausbau System zur Systemparameterabfrage
- Prognose der RUL (Remaining Unit Lifetime)
Soll: 3-6 Tage vor dem Fehler
- KnowHow Aufbau

Falsche Erwartungen, aber positives Ergebnis – TEST-FUCHS

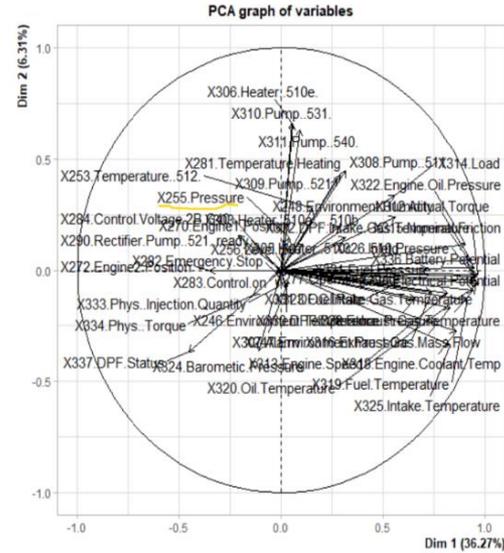
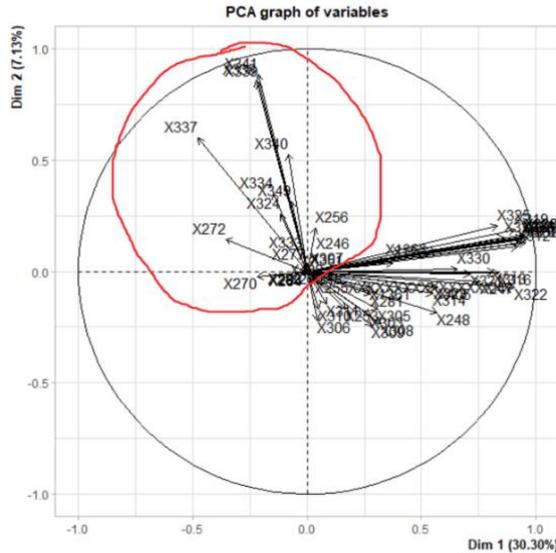
Datenaufbau

- 144 Parameter
- 348.000 Datensätze
- 1 Gerätetyp
- 5 unterschiedliche Geräte
- Messwerte im Abstand von Millisekunden
- Klassifizierung über den Parameter 255 Pressure (>=70 Bar)

data_id	schema_id	address	name	datatype_id
232	7	0	CPU Temperature	4 {
233	7	1	IP Address	7 {
234	7	10	LiFePO4wered VIN	1 {
235	7	11	LiFePO4wered VBAT	1 {
236	7	12	LiFePO4wered VOUT	1 {
237	7	13	LiFePO4wered IOUT	1 {
238	7	14	LiFePO4wered AUTO_BOOT	1
239	7	15	LiFePO4wered WAKE_TIME	1
240	7	16	LiFePO4wered AUTO_SHDN_TIME	2
241	7	17	LiFePO4wered RTC_TIME	3
242	7	20	Location	11 {

Falsche Erwartungen, aber positives Ergebnis – TEST-FUCHS

Datenreduktion: Principal Component Analysis (FactoMineR)
 - 16 Parameter sind übriggeblieben



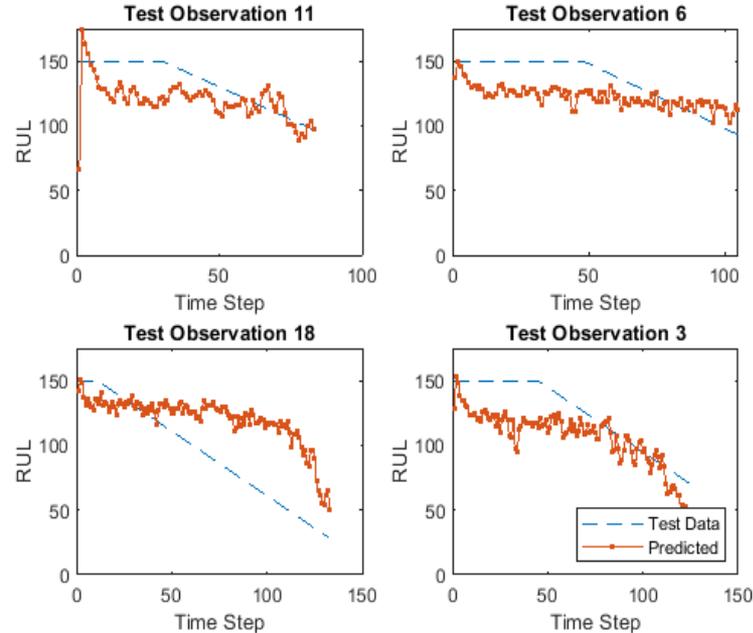
Falsche Erwartungen, aber positives Ergebnis – TEST-FUCHS

Problem - aus 348.000 Datensätzen wurden 120

- Es waren nur 120 relevante Fehlerfälle enthalten
- Alle Testfälle waren zeitlich zu „kurz“
- Lösung: weitere Daten wurden gesammelt (6 Monate)

Dennoch waren die Ergebnisse nicht mal so schlecht!

Ein eindeutiger Trend war zu erkennen.



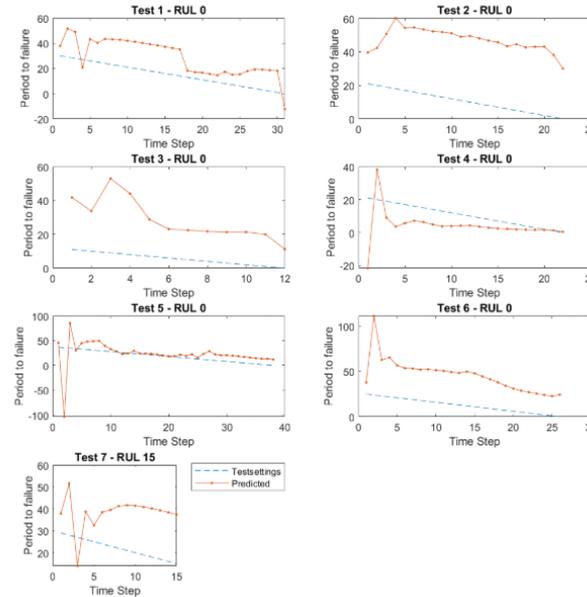
Falsche Erwartungen, aber positives Ergebnis – TEST-FUCHS

Zweiter Versuch

- 380 Fehlerfälle (wieder zu wenig)
- Zusammenführung der
 Detaildaten auf
 10 Minuten Basis (Max-Werte
 und Mittelwerte)

Kein akzeptables Ergebnis, aber ...

... der Kunde hat den Grund für den
 Überdruck gefunden und das Problem
 behoben.

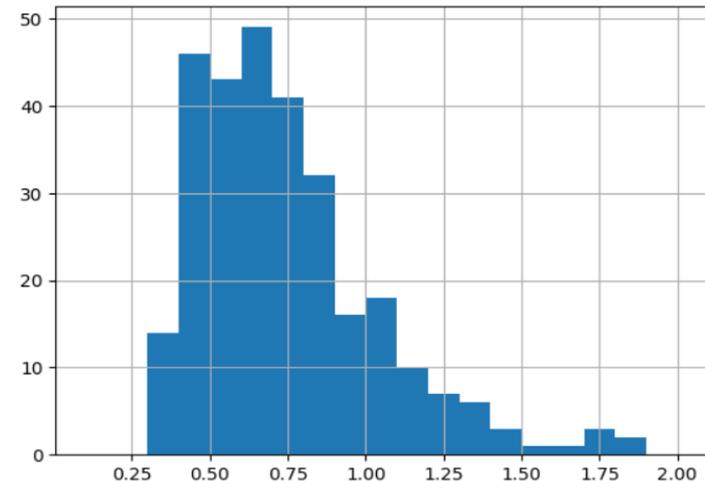


- Autoencoder / Transferlearning
- LLM – ChatGPT

Autencoder / TransferLearning

QS in der Schraubenproduktion

- Zu überprüfen ist ein KI Ansatz zur Vorhersage der Bohrzeit aus dem Bild der Schraube.
- Problem: 3% Ausschuss führt zu Problemen bei der Abnahme der Lieferung.
- Ziel: InSitu Monitoring in der Produktion.



Autencoder / TransferLearning

Bild Vorbereitung: Bildausschnitt wählen / Auflösung ändern

2268 Pixel
1,2 MB

->
->

200 Pixel
5kb



Autencoder / TransferLearning

Bild Vorbereitung: Bildausschnitt wählen / Auflösung ändern

Gute Schraube
0,5 Sek.

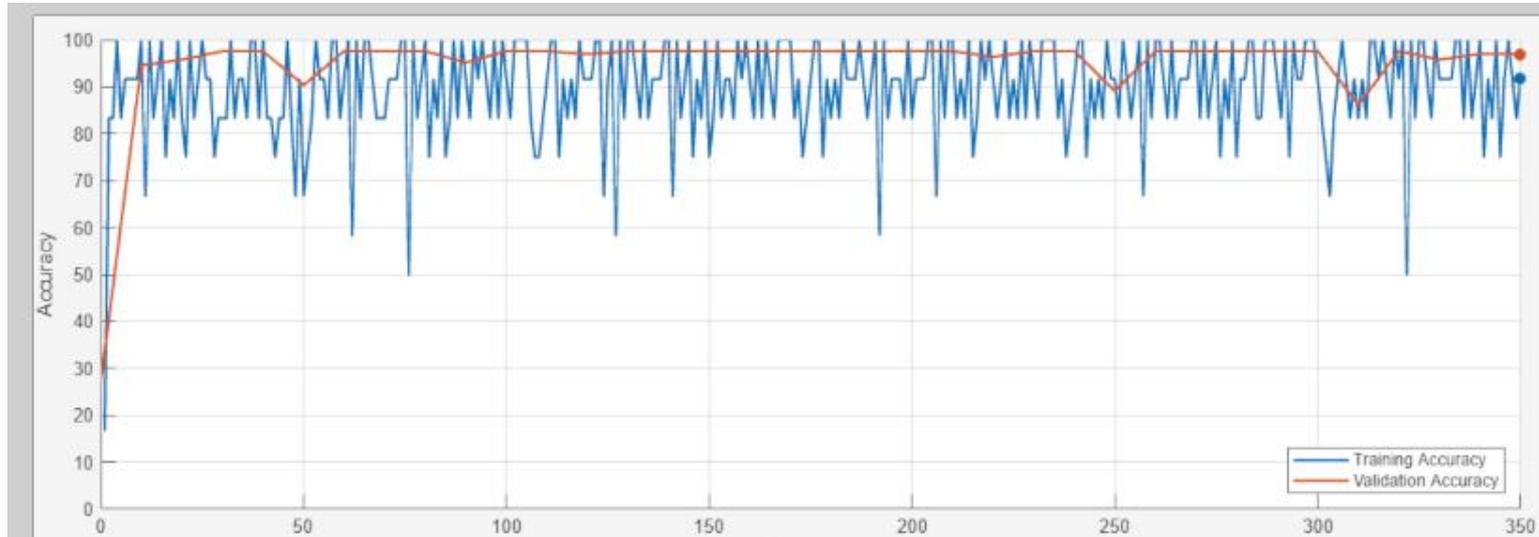


Schlechte Schraube
1,4 Sek.



TransferLearning

Pretrained Network: ResNet101
70% Trainingsdaten – 30% Testdaten
Trainingszeit: 2 Minuten, 6 Epochen
Genauigkeit: 92%



TransferLearning

Vorteile Transferlearning

- Kurze Rechenzeit
- Vortrainierte Netze „können“ mit Bildgebenden Problemen umgehen (Schattierungen, Blendungen)
- Vortrainierte Netzwerke „kennen“ Objekte (Hintergrund/Vordergrund)
- Bilder müssen nicht speziell zugeschnitten sein

Nachteile Transferlearning

- Man erkennt nicht, warum das trainierte Modell die Schrauben unterscheiden kann

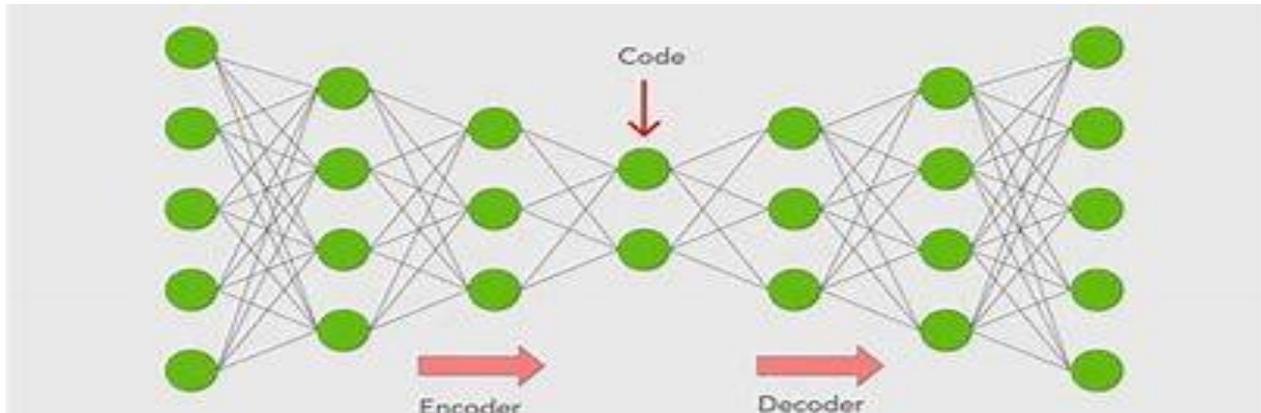
Nach 15 Stunden Trainingszeit:

Gute Schraube Genauigkeit: 99,31%

Schlechte Schraube Genauigkeit: 87,45%

Autoencoder

- erlernt eine kompakte Repräsentation (Encoding) eines Datensatzes
- um die Eingabedaten (Decoding) so genau wie möglich zu rekonstruieren
- erspart unter Umständen viel Zeit (keine Klassifizierung)
- „zeigt“ den Fehler

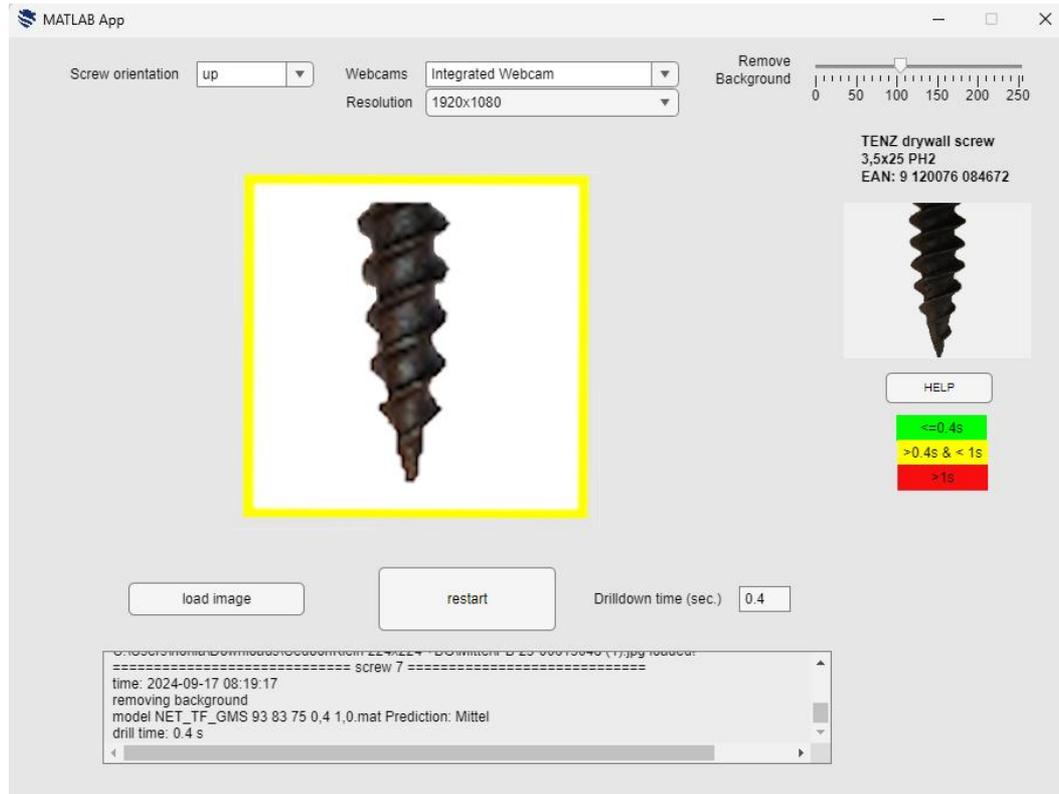


Autoencoder

- Durch Vergleich des decodierten Bildes im Vergleich mit dem realen Bild bekommt man einen Wert – z.B. mseError 775,22



MATLAB Framework



The screenshot shows a MATLAB App window titled "MATLAB App". The interface includes several control elements:

- Screw orientation:** A dropdown menu set to "up".
- Webcams:** A dropdown menu set to "Integrated Webcam".
- Resolution:** A dropdown menu set to "1920x1080".
- Remove Background:** A slider control ranging from 0 to 250, currently set at approximately 100.
- Image Display:** A large central image of a dark screw with a yellow bounding box around it.
- Product Information:** Text on the right side reads "TENZ drywall screw", "3,5x25 PH2", and "EAN: 9 120076 084672". Below this is a smaller image of the screw.
- Classification Legend:** Three colored boxes indicate classification ranges: a green box for " $\leq 0.4s$ ", a yellow box for " $> 0.4s \ \& \ < 1s$ ", and a red box for " $> 1s$ ".
- Buttons:** "load image" and "restart" buttons are located at the bottom left.
- Drilldown time (sec.):** A text input field containing "0.4".
- Command Window:** A scrollable area at the bottom showing the following text:

```
===== screw 7 =====  
time: 2024-09-17 08:19:17  
removing background  
model NET_TF_GMS 93 83 75 0,4 1,0.mat Prediction: Mittel  
drill time: 0.4 s
```

• Fördermöglichkeiten

Wirtschaftskammer NÖ

TIP Schwerpunktberatung

80h Förderung á €55,-

<https://www.tip-noe.at/foerderungen>

AWS

Digitalisierung: Künstliche Intelligenz

<https://www.aws.at/aws-digitalisierung/kuenstliche-intelligenz>

Land Niederösterreich

<https://calls.einreichsystem.at/#FTI21-A>

Forschung und Entwicklung

http://www.noegv.at/noe/Wirtschaft-Tourismus-Technologie/Foerd_Forschung-Entwicklung.html

Technologie – Förderung

<https://www.noegv.at/noe/Wirtschaft-Tourismus-Technologie/Technologiefoerderung.html>

• Fördermöglichkeiten

FFG

Collective Research

65% Förderung

<https://www.ffg.at/en/en/programme/collective-research>

Digital Skills Scheck

max. €1000,- pro Person

<https://www.ffg.at/ausschreibungen/DigitalSkillsSchecks-1-Ausschreibung>

Innovationsscheck

80% Förderung

max. €10.000,-

<https://www.ffg.at/ausschreibungen/InnovationsscheckmitSelbstbehalt>

Kleinprojekt

60% Förderung

<https://www.ffg.at/programm/kleinprojekt>

BIG-DATA in der Produktion

<https://www.ffg.at/bigdatainderproduktion>

Basisprogramm

<https://www.ffg.at/programm/basisprogramm>

Gerne stehen wir Ihnen für weitere
Informationen zur Verfügung.

DI(FH) Markus Hohlagschwandtner, MSc

+43 5 0421 8130

hohlagschwandtner@fotec.at



VIELEN DANK!