

Johannes Gerritzen¹; Dr.-Ing. Andreas Hornig; Prof. Dr.-Ing. habil. Maik Gude
Institute of Lightweight Engineering and Polymer Technology

Effiziente Bestimmung von Materialkennwerten in Faser-Kunststoff-Verbunden durch Deep Learning

ProKI InfoPoint – Materialcharakterisierung // 11.05.2023

¹johannes.gerritzen@tu-dresden.de

Motivation

Importance of high fidelity material models

Predictive modeling

Study of variants

— Trigger geometry of crash absorbers

➔ **Resource efficiency**

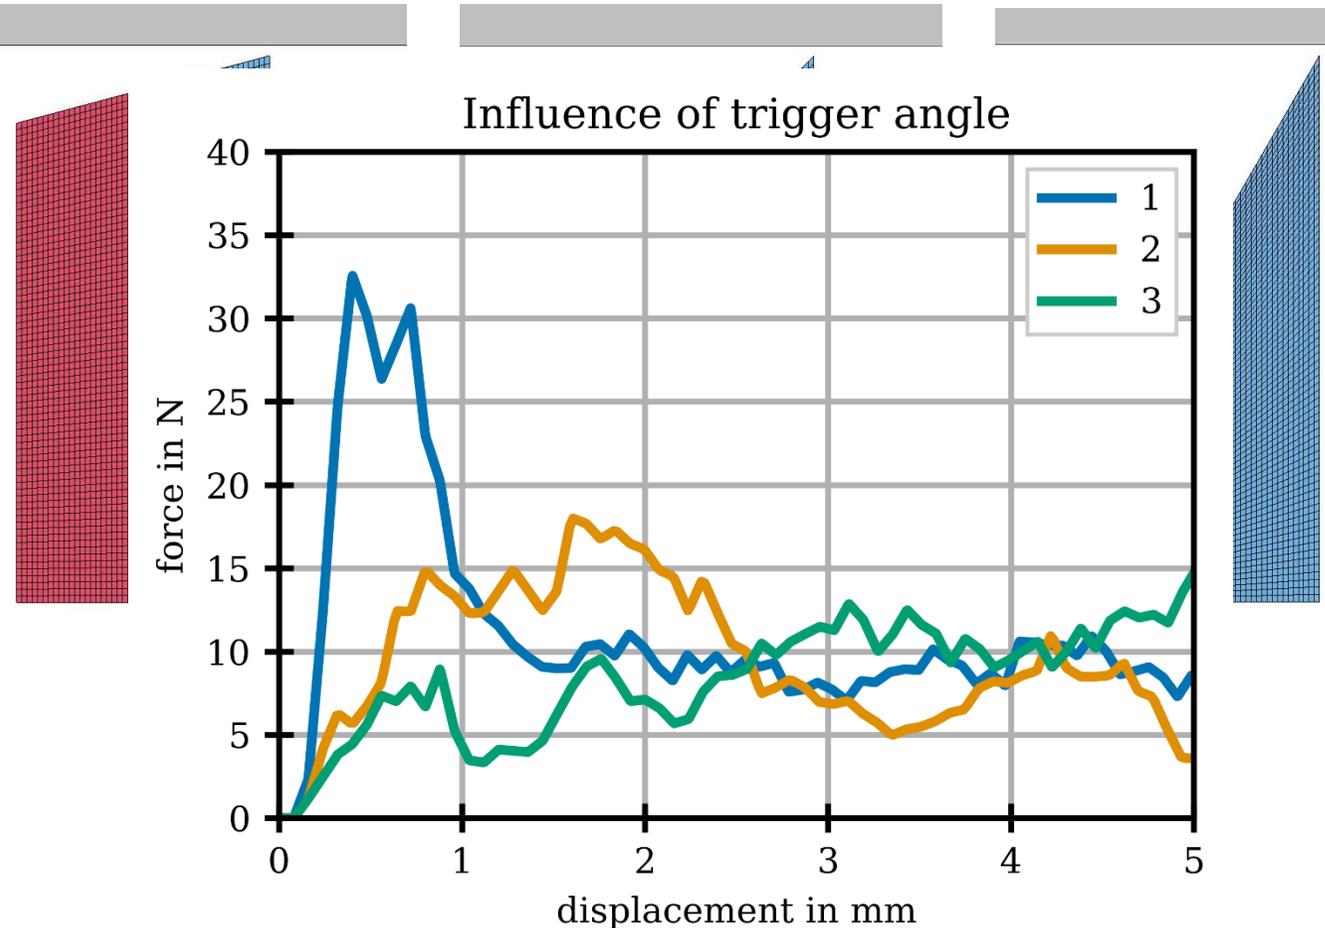
Design optimization

Fully exploit lightweight potential

Resulting Problem

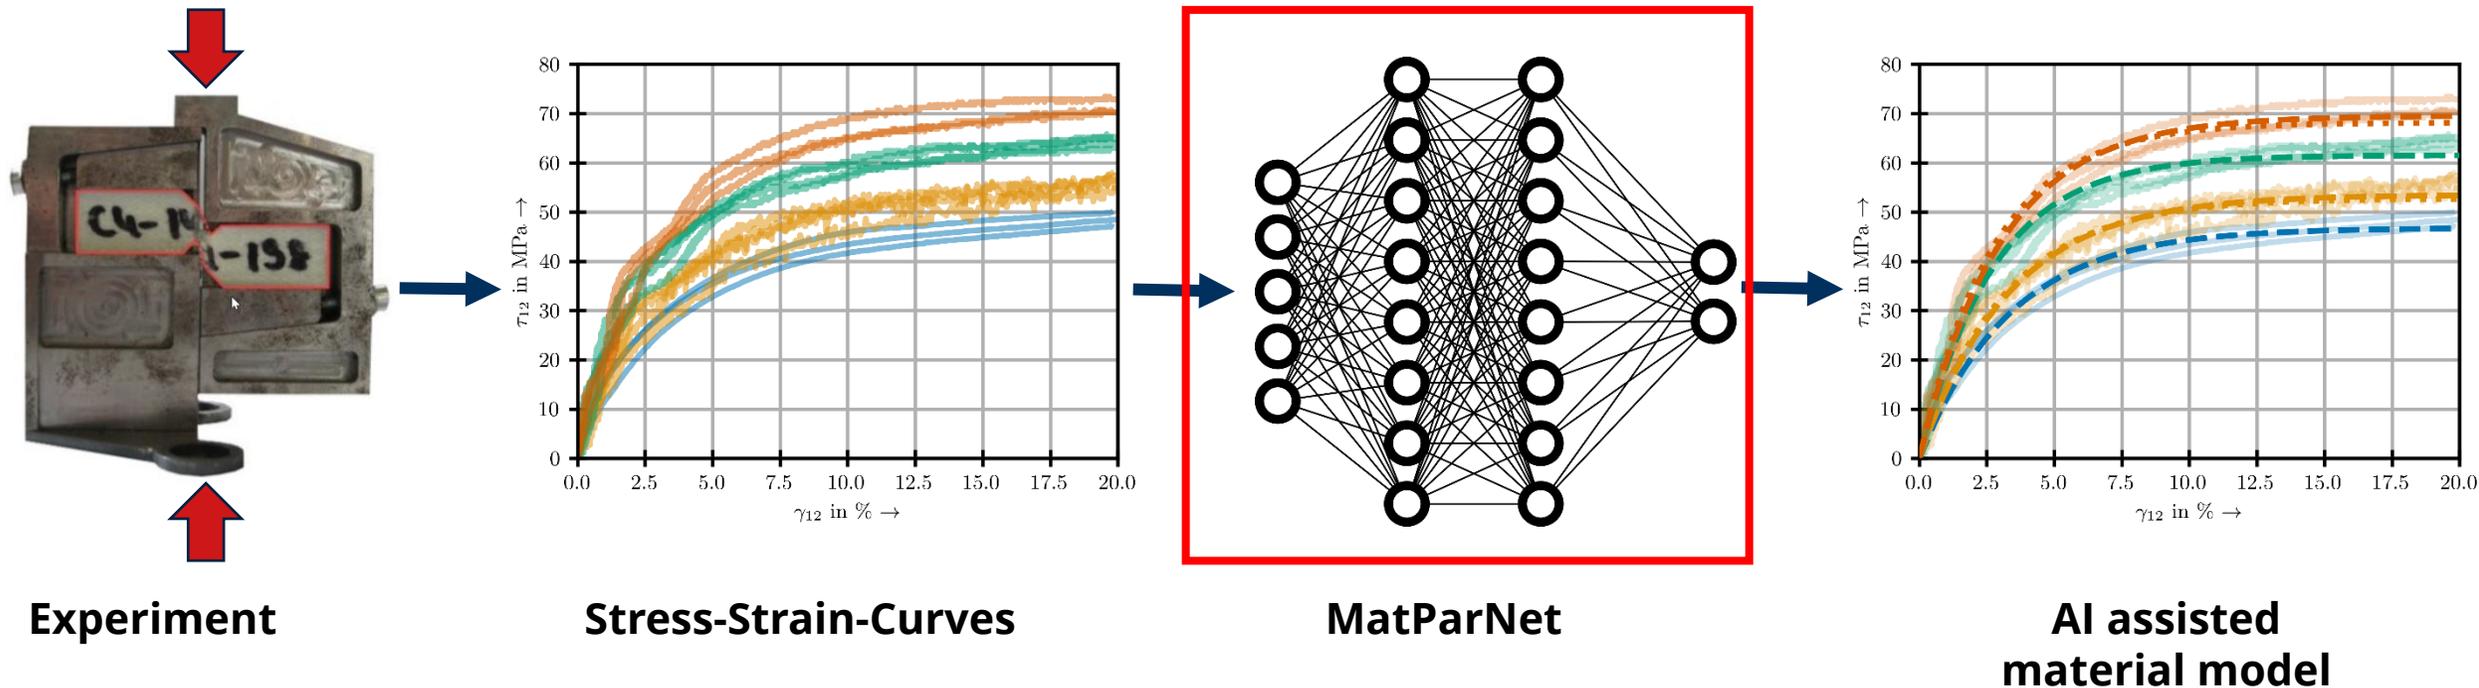
Complex experiments and evaluation

Parameter extraction requires good model understanding



Approach

Deep Learning for determining model specific parameters from experimental data



➔ Simplify application of high fidelity material models

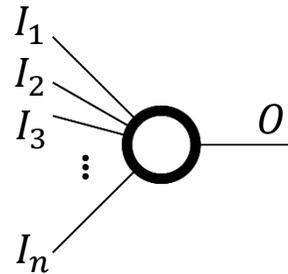
Basics of Neural Networks

Fully Connected Layers

Single Neuron

$$O = f(w_i I_i + b)$$

$$f(x) = \max(0, x)$$



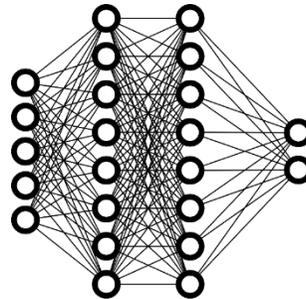
Assembly to Network

— Layerwise connection

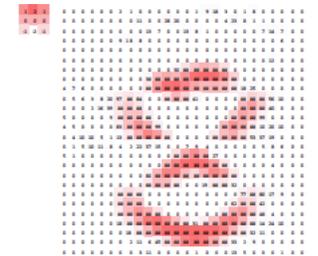
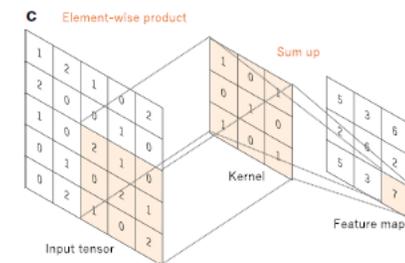
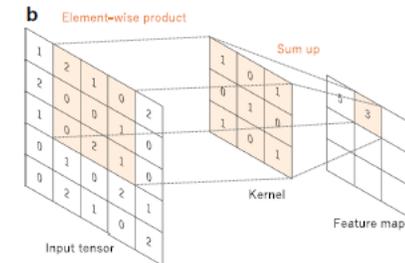
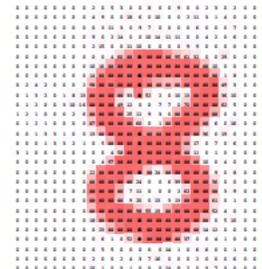
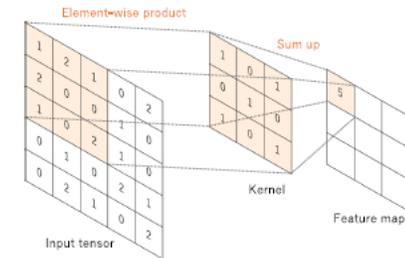
$$I_k \equiv O_{k-1}$$

— Output layer with linear activation

$$f(x) = x$$



Convolutional Layer (2D example)



n overview and application in radiology.
).1007/s13244-018-0639-9

Training Data

Extraction of relevant aspects in experimental data

Variation in

- maximum strain value
- distance between strain values
- number of points

Noise

Intended material model

Rough estimate of parameter ranges

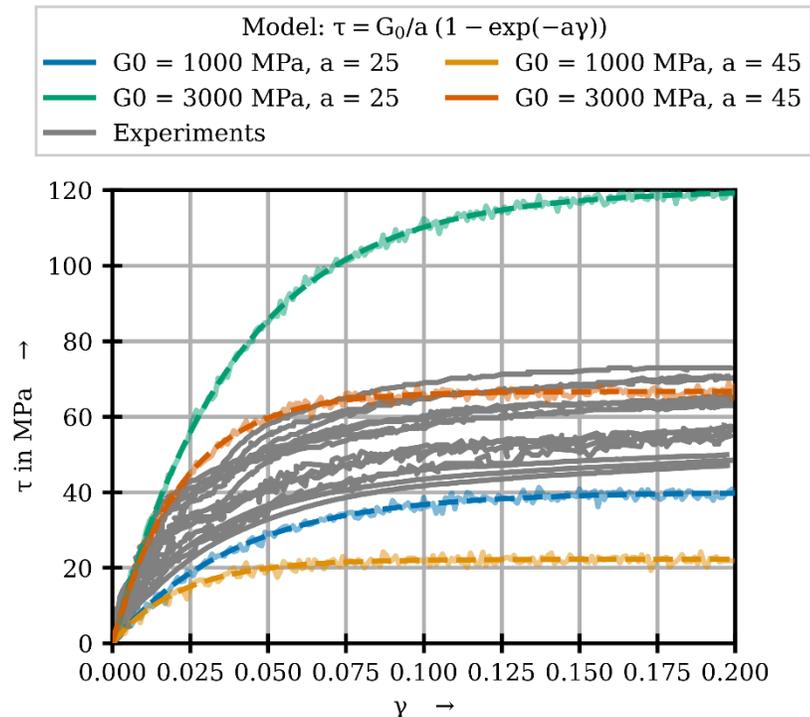
Additional virtual modeling aspects

Sampling method

Number of virtual samples

Data preprocessing

Comparison of experimental and virtual data



Modeling decisions

Hyperparameters

Network architecture

Fully connected

- Number of layers
- Number of neurons per layer
- (Activation function)

Convolution

- Number of layers
- Number of filters per layer
- Window size
- Padding
- Pooling
- (Activation function)

Skip connections

Training

Number of epochs

Learning rate

Batch size

Error metric

Early stopping

Weight initialization

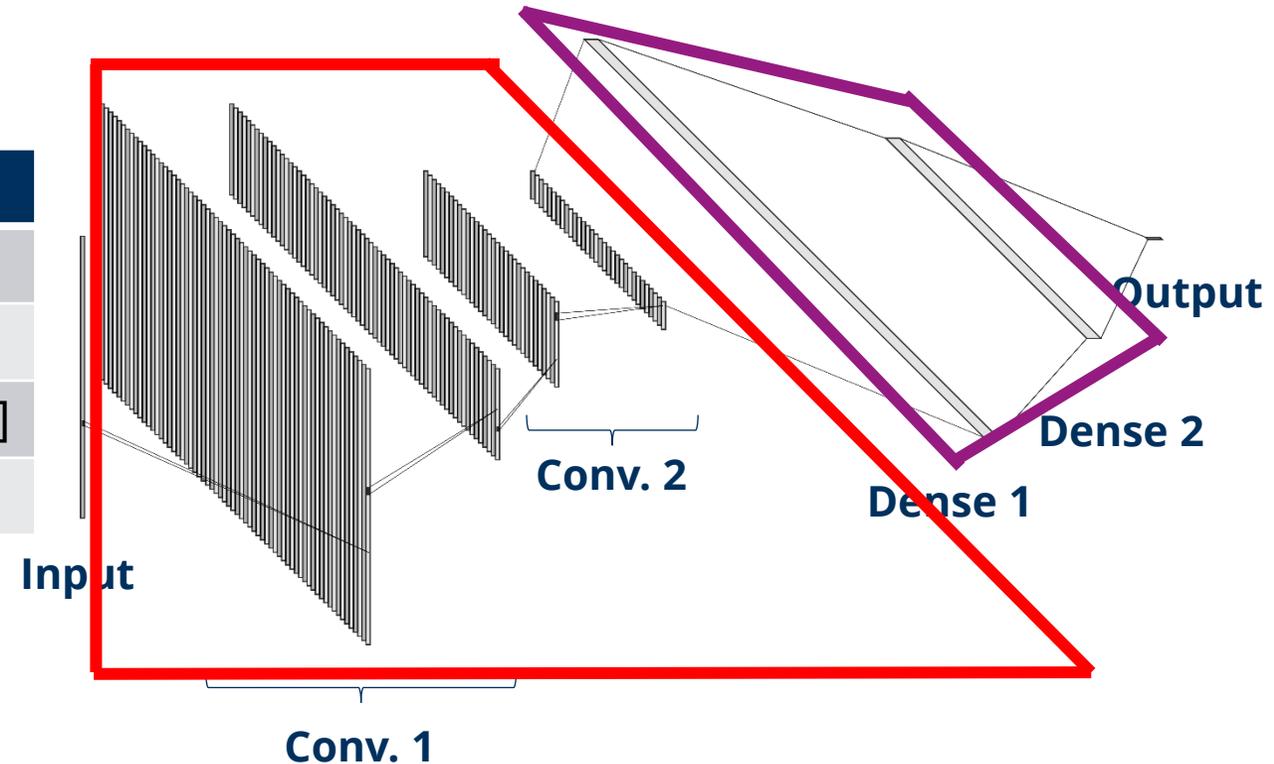
Optimizer

- Specific parameters

Investigation

Reduced factorial DOE

Variable	Values
# conv	[0, 1, 2]
# dense	[0, 1, 2, 3, 4]
# samples	[100, 1000, 10000 , 100000, 500000]
noise	yes, no



Model implementation

Using high level library "tensorflow"

Network setup

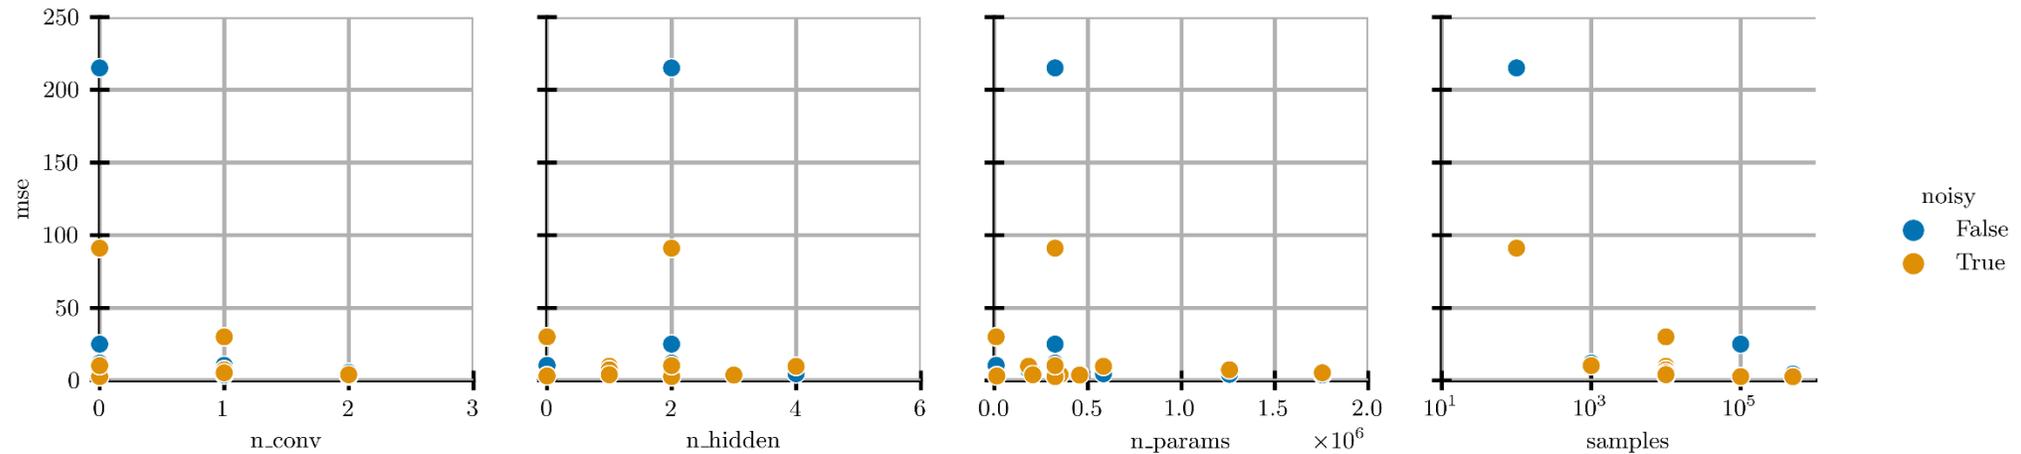
```
1 model = Sequential()
2
3 # Input layer
4 model.add(Input(shape=(x_train.shape[1], x_train.shape[2])))
5
6 # Convolutional layers
7 for filters in num_filters:
8     model.add(Conv1D(filters, window, activation="relu"))
9     model.add(MaxPooling1D(pool))
10
11 model.add(Flatten())
12
13 # Fully connected layers
14 for neurons in num_hidden:
15     model.add(Dense(neurons, activation="relu"))
16
17 # Output layer
18 model.add(Dense(y_train.shape[1], activation="linear"))
```

Training

```
1 model.compile(loss='mean_squared_error', optimizer="adam")
2
3 model.fit(
4     x_train,
5     y_train,
6     validation_data=(x_test, y_test),
7     epochs=epochs,
8     shuffle=True,
9     batch_size=batch_size
10 )
```

Results

Influence of hyperparameters

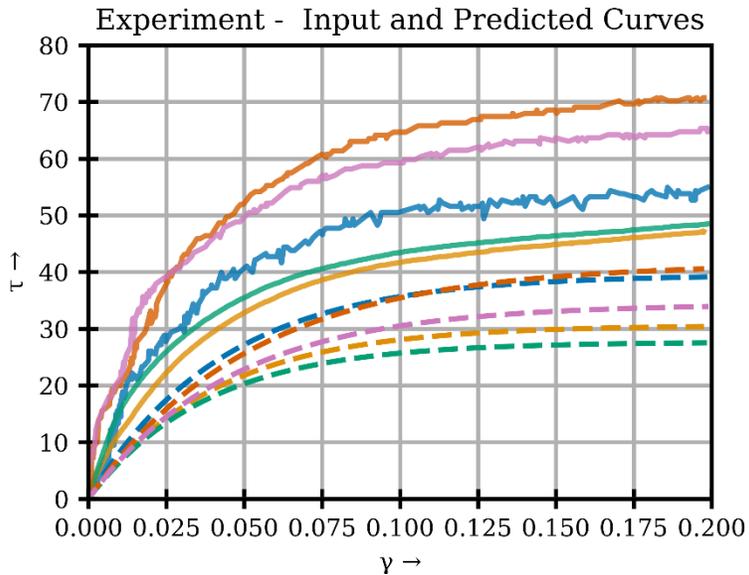


- Larger networks tend to yield better results
- Convolutional layers are more efficient for parameter extraction than fully connected
- Increase in size of training dataset can compensate for simpler data

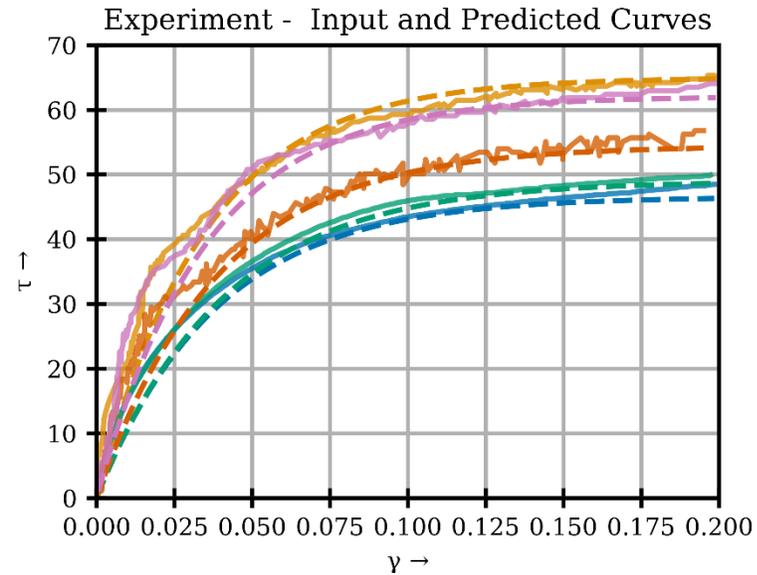
Results - Curve comparison

Reference network $n_{\text{conv}}=0$, $n_{\text{hidden}}=2$; **with** noise

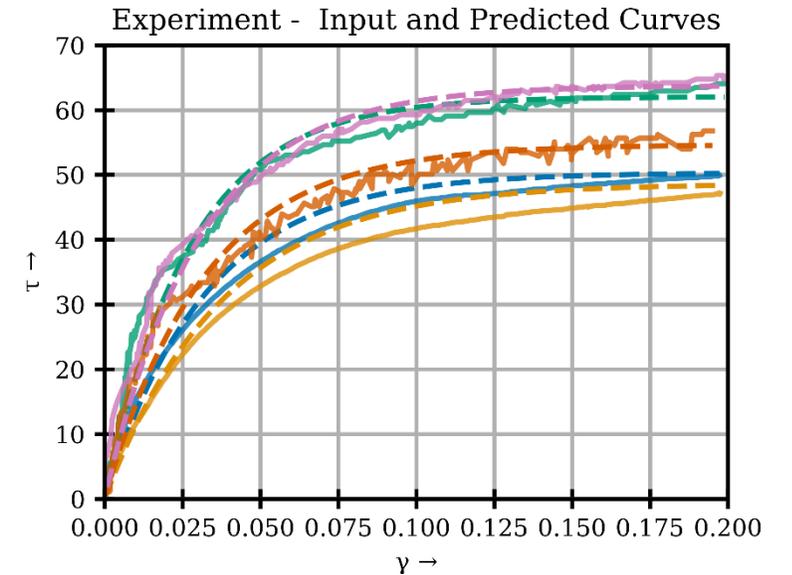
$n_{\text{samps}} = 100$



$n_{\text{samples}} = 10,000$



$n_{\text{samples}} = 500,000$



Results – Curve comparison

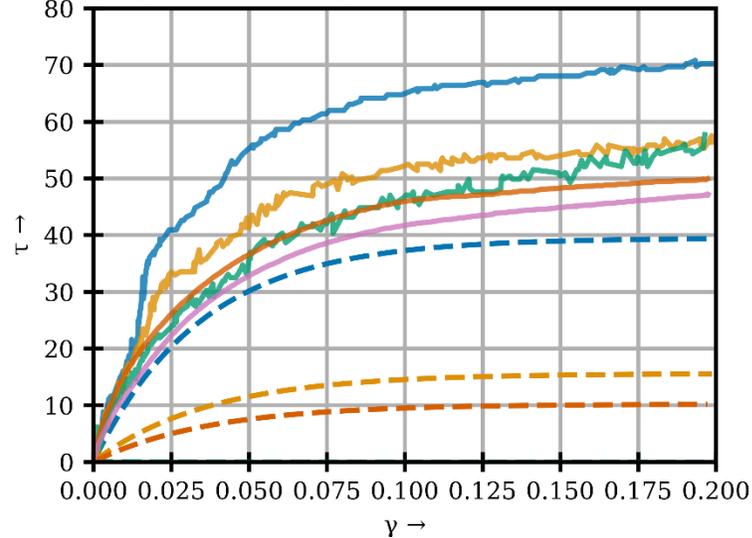
Reference network $n_{\text{conv}}=0$, $n_{\text{hidden}}=2$; **without** noise

$n_{\text{samps}} = 100$

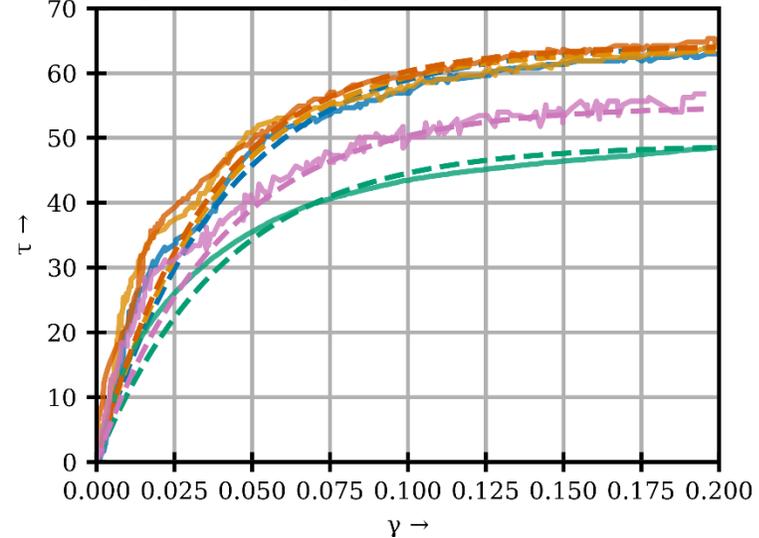
$n_{\text{samples}} = 10,000$

$n_{\text{samples}} = 500,000$

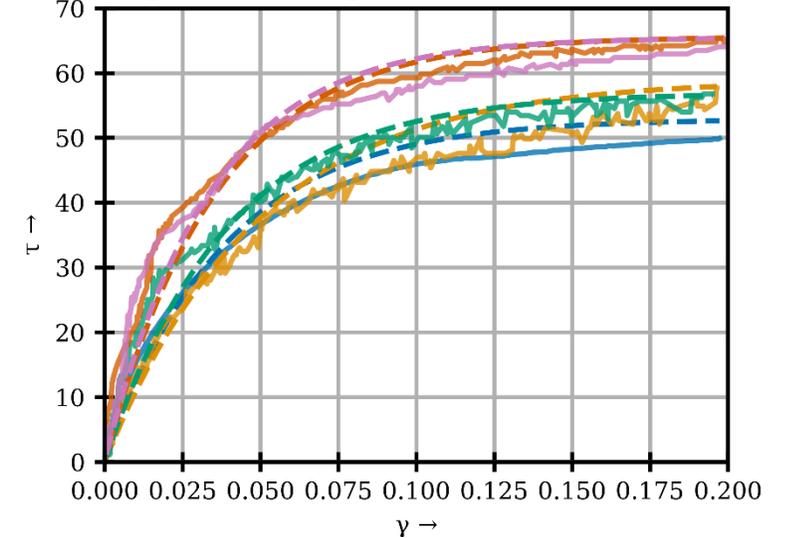
Experiment - Input and Predicted Curves



Experiment - Input and Predicted Curves



Experiment - Input and Predicted Curves



Conclusion

Usage of machine learning techniques allows for parameter identification from experimental data

Highly non-linear models

Training data without noise

Purely virtual training data

Implementing and training neural networks for well defined tasks can be straight forward

Variety of high level libraries

Choice of hyperparameters is important

→ Allow for the usage of use-case specific material models to fully exploit light weight potential

Acknowledgments



The authors acknowledge the financial support by the Federal Ministry of Education and Research of Germany and by the Sächsische Staatsministerium für Wissenschaft Kultur und Tourismus in the program Center of Excellence for AI-research “Center for Scalable Data Analytics and Artificial Intelligence Dresden/Leipzig”, project identification number: ScaDS.AI.

Alexander Wolf, Prof. Dr.-Ing. Alexander Brosius
Professur für Formgebende Fertigungsverfahren | Institut für Fertigungstechnik

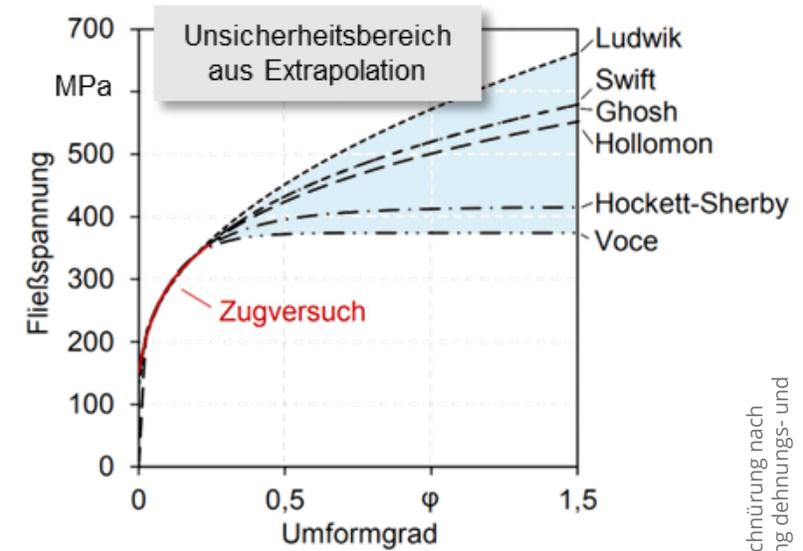
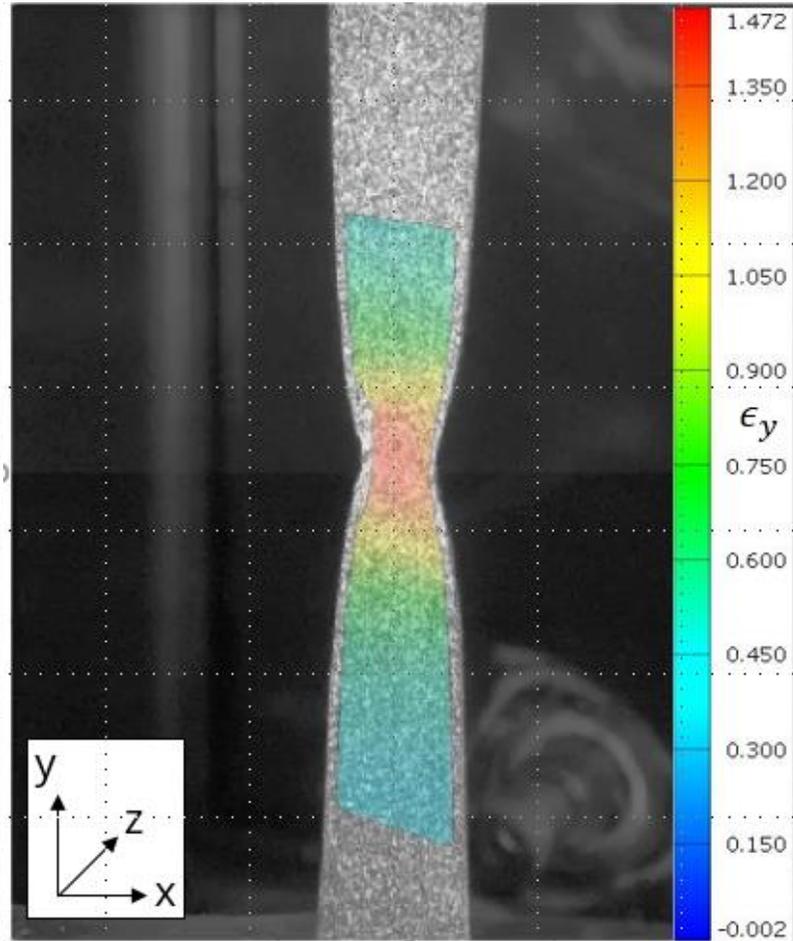
Werkstoff und KI

Werkstoffcharakterisierung mit Hilfe von
Künstlichen Neuronalen Netzen (KNN)

6. ProKI-Infopoint
11.05.2023

Werkstoffcharakterisierung mit Hilfe von Künstlichen Neuronalen Netzen (KNN)

Ausgangssituation



Zugversuch als Versuch zur Kennwertermittlung und die Nutzung für die Finite-Elemente-Methode

Abbildung nach D. Jocham, „Bestimmung der lokalen Einschnürung nach linearer und nichtlinearer Umformhistorie sowie Ermittlung dehnungs- und geschwindigkeitsabhängiger Materialkennwerte“.

Werkstoffcharakterisierung mit Hilfe von Künstlichen Neuronalen Netzen (KNN)

Ausgangssituation

- **Konventionelle Auswertung** von Zugversuchen (DIN 6892-1 o. ASTM E8) nur bis zum Erreichen der Gleichmaßdehnung möglich
- Größer Unsicherheitsbereich aus der Extrapolation heraus

Zielsetzung

- Auswertung des Zugversuchs über die Gleichmaßdehnung hinaus mithilfe von KNN und virtuellen Versuchen
- Spannungskorrektur in der Einschnürung mittels KI-Ansatz
→ Verbesserung der Datengrundlage für die Fließkurven-Extrapolation

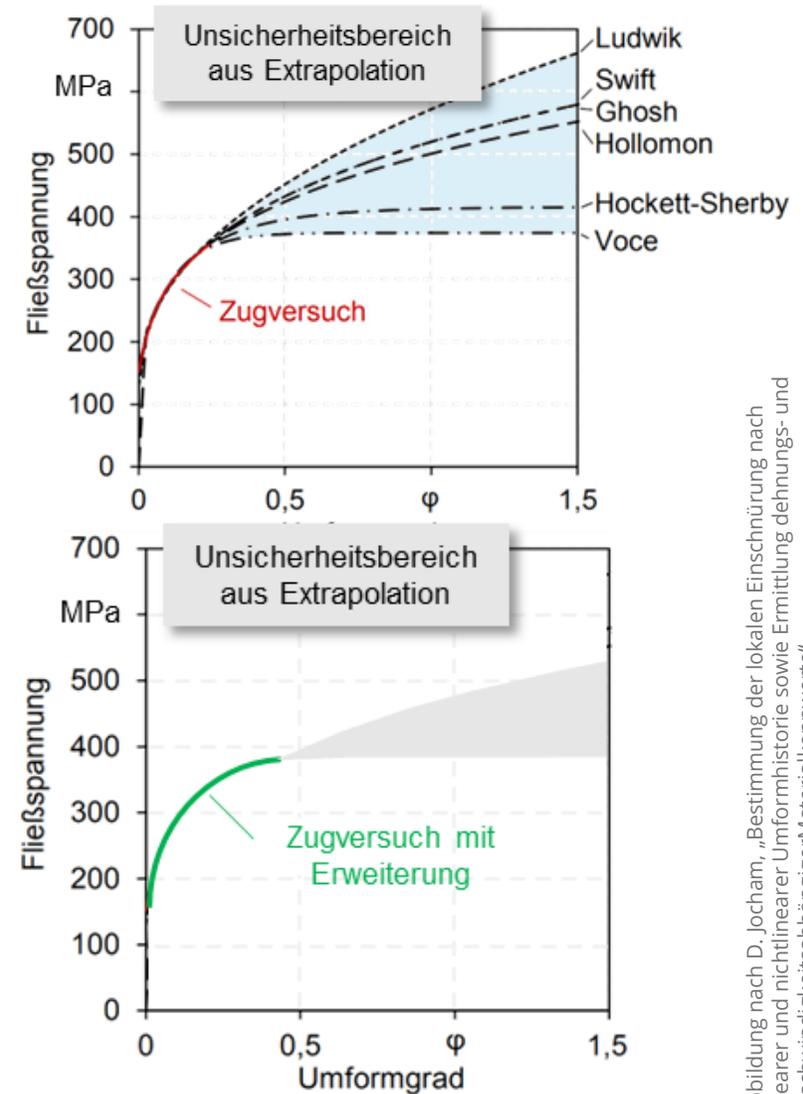


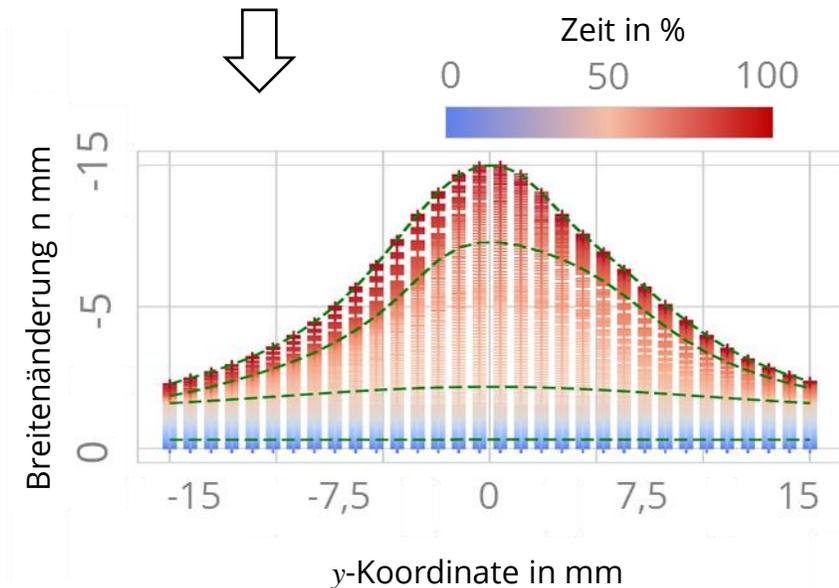
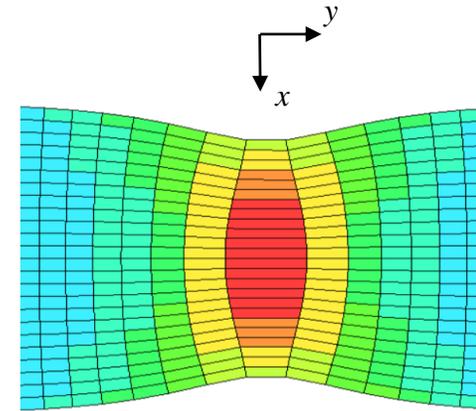
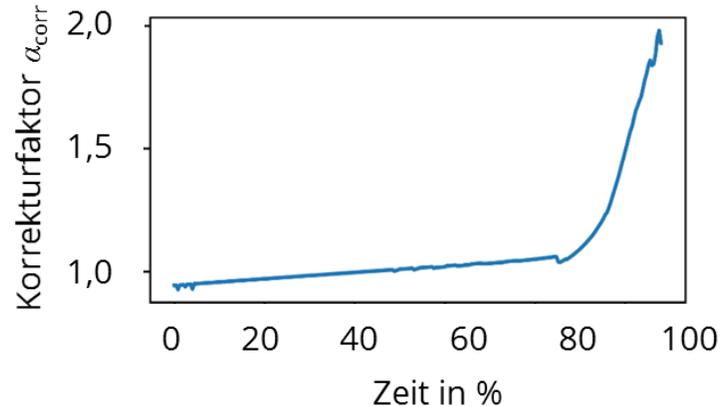
Abbildung nach D. Jocham, „Bestimmung der lokalen Einschnürung nach linearer und nichtlinearer Umformhistorie sowie Ermittlung dehnungs- und geschwindigkeitsabhängiger Materialkennwerte“.

Werkstoffcharakterisierung mit Hilfe von Künstlichen Neuronalen Netzen (KNN)

Methode

- Bestimmung eines Korrekturfaktors für die Spannung in der Einschnürzone mit Hilfe von Künstlichen Neuronalen Netzen
- Training mit synthetischen Daten, die mit Finite-Elemente-Simulationen erzeugt wurden
- Geometrische Informationen der Einschnürungsregion dienen als Eingabedaten
- Output-Daten: Spannungs-Korrekturfaktor

$$\alpha_{corr} = \frac{\sigma_y}{\sigma_{true}}$$



Werkstoffcharakterisierung mit Hilfe von Künstlichen Neuronalen Netzen (KNN)

Methode

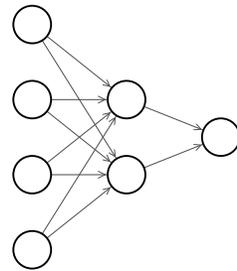
- Dateninput:
 - Explizite FEM mit dem Yld2000-2D Modell nach Barlat
 - Ein Verfestigungsansatz (Swift)
 - Anisotropes Verfestigungsverhalten
- Verarbeitung:
 - Stichprobengenerierung mittels Latin-Hypercube-Verfahrens
 - Datenextraktion via Python-Skript

Parameter	Minimum	Maximum
k in MPa	600	1200
ϵ_p	0.02	0.05
n	0.05	0.3
α_{1-8}	0.4	1.7

Werkstoffcharakterisierung mit Hilfe von Künstlichen Neuronalen Netzen (KNN)

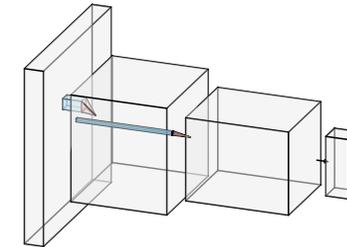
Methode

- Zwei der bekanntesten und meist genutzten Topologien wurden getestet
 - Multilayer perceptrons (MLP) and convolutional neural networks (CNN)
- ca. 1000 Modelle wurden trainiert



MLP

Hyperparameter	Minimum	Maximum
Learning rate	0.00001	0.1
Model parameters	351	15,145



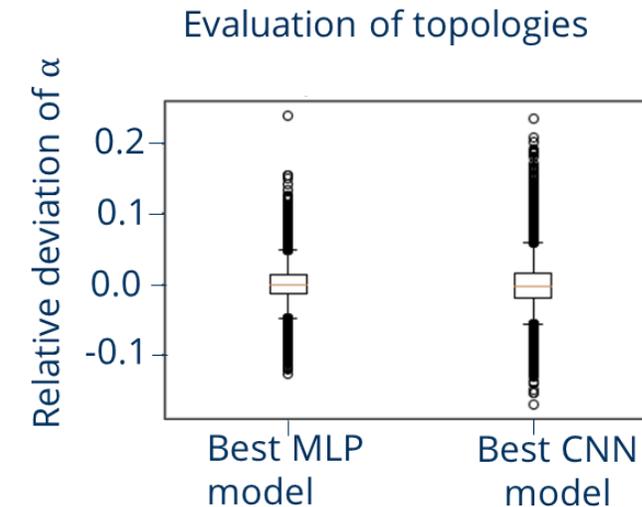
CNN

Hyperparameter	Minimum	Maximum
Learning rate	0.0001	0.1
Model parameters	2,413	13,444

Werkstoffcharakterisierung mit Hilfe von Künstlichen Neuronalen Netzen (KNN)

Ergebnisse des vorgestellten Ansatzes

- Die besten Modelle beider Topologien erreichen eine ähnliche Leistung auf Basis der Simulationsdaten
- Die relative Abweichung der Vorhersagen von den realen Werten beträgt 5-6 % mit einem Konfidenzintervall von 95 %
- Das MLP-Modell (16.329 Parameter) ist deutlich komplexer als CNN-Modell (2.407 Parameter)
- Die aktuelle Forschung konzentriert sich deshalb auf das CNN-Modell, da es bei einfacherem Aufbau eine ähnliche Leistung erbringt

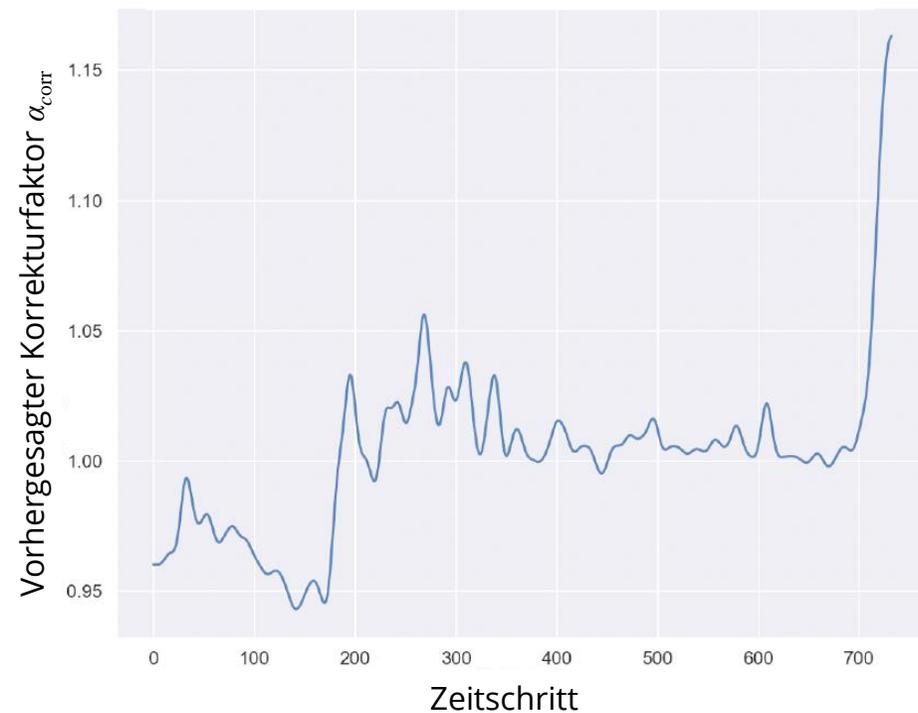


Werkstoffcharakterisierung mit Hilfe von Künstlichen Neuronalen Netzen (KNN)

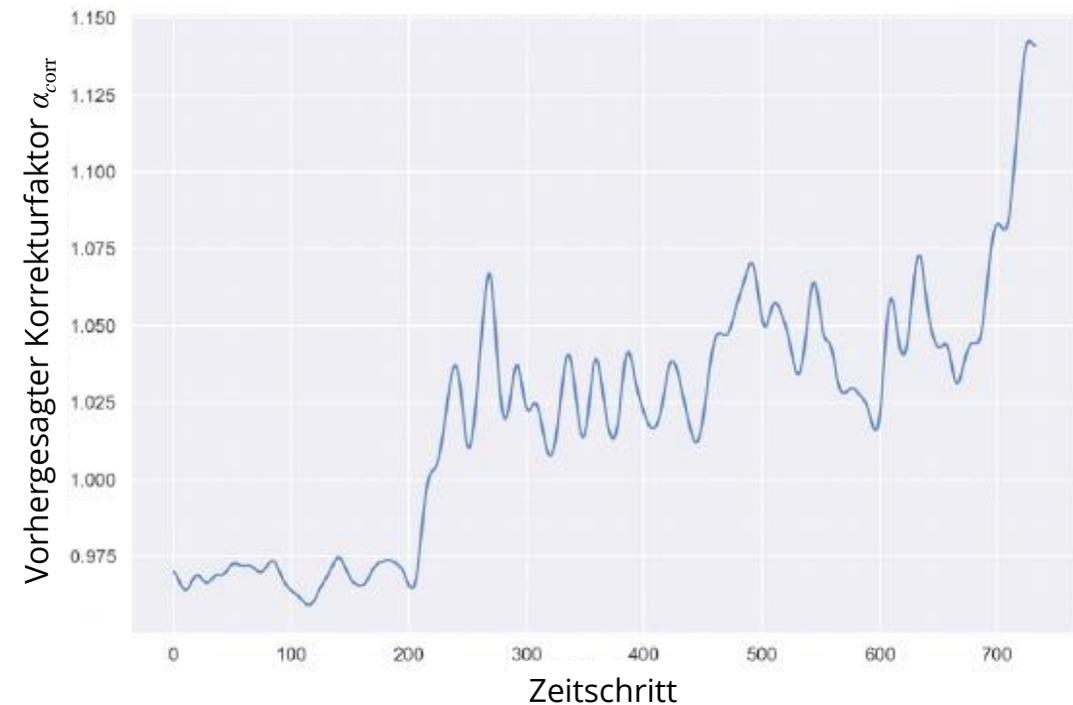
Ergebnisse des vorgestellten Ansatzes

- Anwendung der Modelle für reale Zugversuche

Korrekturfaktor MLP



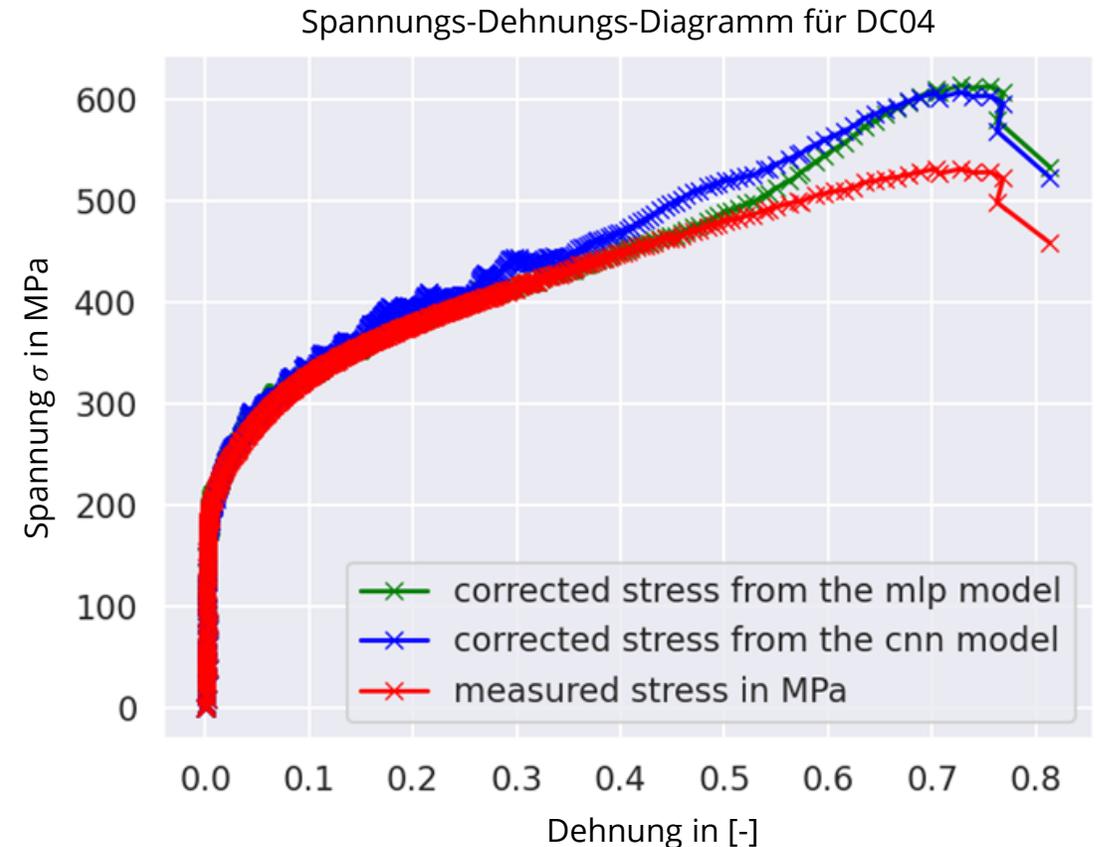
Korrekturfaktor CNN



Werkstoffcharakterisierung mit Hilfe von Künstlichen Neuronalen Netzen (KNN)

Ergebnisse des vorgestellten Ansatzes

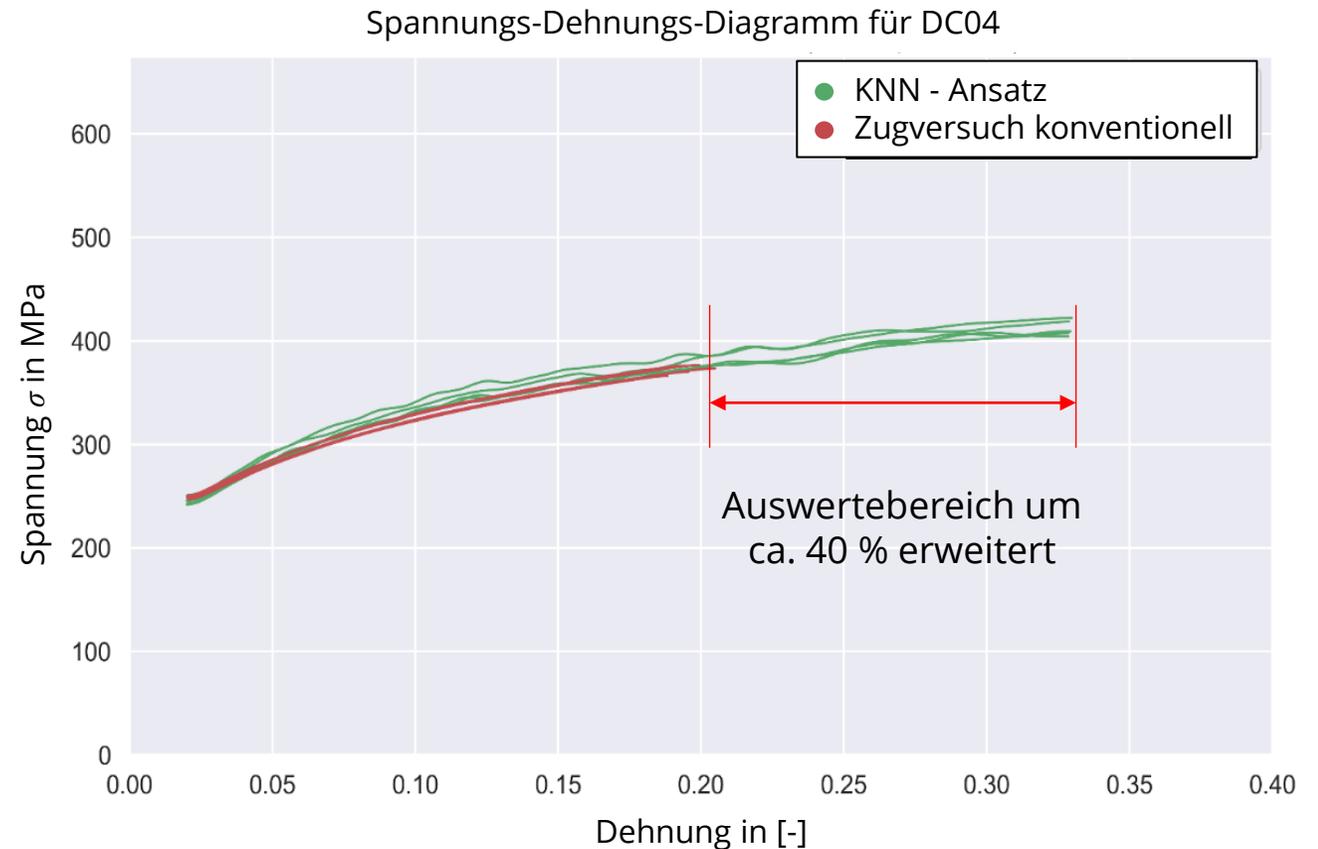
- Gut übereinstimmende Spannungsverläufe auf Grundlage der Eingabedaten
- Ab einem Bereich von $\varepsilon = 0.4$ ist die Datengrundlage für die Modelle nicht gut genug
- Starke Abweichung im späteren Verlauf der Spannung
- Mit einer Datenbasis, die die Realität besser wiedergibt, kann die Genauigkeit der KI-Methode verbessert werden



Werkstoffcharakterisierung mit Hilfe von Künstlichen Neuronalen Netzen (KNN)

Zusammenfassung

- Erweiterung des Auswertebereichs und damit Verbesserung der Extrapolationsvorhersage für die Fließkurve
- Grundlegender Nachweis der Nutzbarkeit von KNN für die Werkstoffcharakterisierung
- Genauere Ergebnisse auf der Grundlage synthetischer Daten, die aus der FE-Simulationen stammen
- Robustere Modelle durch Verwendung einer breiteren Datenbasis als kommende Schritte (kinematische Verfestigung, Verfestigungsgesetze)



Hakenbeck, F., Lafarge, R., & Brosius, A. (2022, May). Postnecking evaluation of the tensile test using artificial neural networks. In *IOP Conference Series: Materials Science and Engineering* (Vol. 1238, No. 1, p. 012048). IOP Publishing.

Werkstoffcharakterisierung mit Hilfe von Künstlichen Neuronalen Netzen (KNN)



GEFÖRDERT VOM



Bundesministerium
für Bildung
und Forschung

Werkstoffcharakterisierung mit Hilfe von Künstlichen Neuronalen Netzen (KNN)

Bei Fragen und Kommentaren kontaktieren Sie uns gern direkt

Prof. Alexander Brosius
Alexander Wolf

alexander.brosius@tu-dresden.de
alexander.wolf3@tu-dresden.de

<https://tu-dresden.de/ing/maschinenwesen/if/ff>



Für weiterführende Informationen abonnieren Sie unseren Newsletter oder besuchen Sie unsere Webseite

GEFÖRDERT VOM



Bundesministerium
für Bildung
und Forschung