

Verwendung von künstlicher Intelligenz zur Charakteri- sierung von roboter- gefertigten Faser- querschnitten

David Roschinski

Motivation und Zielsetzung

Die Nutzung künstlicher Intelligenz hat viele Prozesse in Industrie und Forschung revolutioniert. Einen entscheidenden Anteil daran tragen neuronale Netzwerke. Diese verleihen der KI die Fähigkeit, Muster in Prozessen zu erkennen, präzise Vorhersagen zu treffen und komplexe Berechnungen zu übernehmen. Um diese Eigenschaften zu erhalten, müssen neuronale Netzwerke mit passenden Datensätzen trainiert werden.

In dieser Arbeit werden neuronale Netze zur Berechnung der Flächeninhalte von Faserquerschnitten genutzt. Die Querschnitte stammen von einem künstlich erzeugten Polymerfaserstoff, welcher als Grundlage für Leichtbaukonstruktionen verwendet wird.

Aufbau neuronaler Netzwerke

Abbildung 1 zeigt den Aufbau eines neuronalen Netzwerkes, bestehend aus Neuronen (Knoten) und gewichteten Kanten.

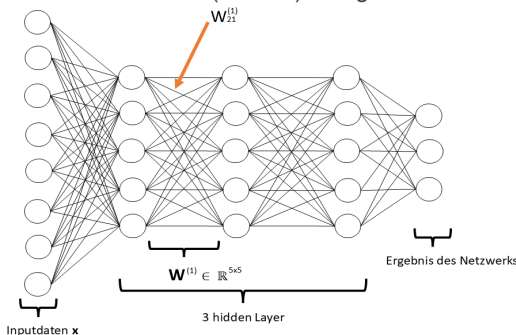


Abb. 1: Aufbau eines neuronalen Netzwerkes

Die Neuronen besitzen einen numerischen Zahlenwert, auch Aktivierung genannt. Ausgehend vom 0.-ten Layer mit den Inputdaten werden die Aktivierungen iterativ für jedes Neuron jedes Layers mit der folgenden Formel berechnet:

$$a^{(l)} = \sigma(W^{(l)}a^{(l-1)} + b^{(l)})$$

$W^{(l)}$ fasst hierbei alle Gewichte zwischen dem $l-1$ -ten und l -ten Layer zusammen. $b^{(l)}$ ist ein zusätzlicher Biasterm.

Die Aktivierung des letzten (L -ten) Layers enthält das berechnete Ergebnis des Netzwerkes. σ ist dabei eine Aktivierungsfunktion, welche dafür sorgt, dass die Aktivierungen vergleichbar bleiben. Zudem hilft σ , nichtlineare Zusammenhänge lernen zu können.

Training neuronaler Netzwerke

Ein neuronales Netzwerk soll unbekannte Daten richtig klassifizieren und neue Ergebnisse ableiten. Um diese Fähigkeit zu erlernen, wird es mit geeigneten Daten trainiert. Das Training basiert auf zwei Schritten, welche für alle Daten durchgeführt werden. Zuerst wird die aktuelle Performance des Netzwerkes untersucht. Hierzu wird das Ergebnis $a^{(L)}$ berechnet und über eine Fehlerfunktion C_x mit dem realen Referenzwert y verglichen (Forward Propagation):

$$C_x = 0,5 \|y - a^{(L)}\|^2$$

Betreuung:

Nicolai Grünvogel M.Sc.

Im Anschluss wird die Kostenfunktion durch Modifikation der Gewichte und Biases minimiert. Hierzu wird das Gradientenverfahren mit Schrittweite η angewendet.

$$W^{(l)\text{neu}} = W^{(l)\text{aktuell}} - \eta \frac{dC_x}{dW^{(l)\text{aktuell}}}$$

$$b^{(l)\text{neu}} = b^{(l)\text{aktuell}} - \eta \frac{dC_x}{db^{(l)\text{aktuell}}}$$

Die Ableitungen können über die Kettenregel für jedes Layer iterativ berechnet werden (Backward Propagation). Um sich nicht zu stark auf einzelne Trainingsbeispiele anzupassen, wird für jedes Datum das Gradientenverfahren nicht bis zur Konvergenz durchgeführt, sondern jeweils nur ein Schritt.

Um ein sehr effektives Netzwerk zu erhalten, kann ein Datensatz mehrmals zum Training verwendet werden. Ein Trainingsdurchlauf wird hierbei als Epoche bezeichnet.

Verbesserungsmöglichkeiten

Bei einem Training über viele Epochen mit wenig Trainingsdaten kann es zu Overfitting kommen. Hierbei beginnt das Netzwerk, die spezifischen Charakteristika der Daten auswendig zu lernen. Dadurch findet keine allgemeine Optimierung der Parameterwerte mehr statt.

Dieser Effekt kann mit der L2-Regularisierung reduziert werden. Diese fügt zur Fehlerfunktion einen Term hinzu, welcher große Gewichte bestraft. Dadurch werden die Effekte des Overfittings weniger stark bis zum Outputlayer weitergegeben.

Ergebnisse und Fazit

Aufgrund der geringen Datenverfügbarkeit werden zur Berechnung der Querschnittsflächeninhalte die Referenzflächeninhalte als Binärzahl codiert. Dies liegt an der Tatsache, dass die Berechnung numerischer Zahlenwerte fehleranfälliger ist als die Festlegung, ob die Output-Neuronen eine 1 oder 0 besitzen sollen. Das trainierte Netzwerk besitzt eine Performance von 55%. Für zuverlässigere Berechnungen werden mehr Trainingsdaten benötigt.

Literatur

Nielsen, M. : [Neural networks and deep learning](#). 2019

Gil Pérez, M. ; Kannenberg, F. ; Zechmeister, C. :

Computational co-design framework for coreless wound fibre-polymer composite structure. 2022