Karlsruher Institut für Technologie

BAUSTATIK

Institut für Baustatik
Leiter: Prof. Dr.-Ing.
S. Freitag

Modellierung 1D-viskoelastischen Materialverhaltens mit künstlichen neuronalen Netzen unter Berücksichtigung innerer Variablen

Julian Egerer

1. Einleitung und Motivation

Die Entwicklung geeigneter Materialmodelle innerhalb der Viskoelastizität zur Beschreibung des Verhaltens von bautypischen Werkstoffen stellt bis heute ein attraktives Forschungsgebiet dar. Die Viskoelastizität erweitert die Elastizitätstheorie um einen zeitabhängigen Faktor, der dem Werkstoff ein „Gedächtnis" gibt. Vorzufinden ist ein solches Materialverhalten bei Polymeren wie Gummi oder kommerziellem Plastik, Naturfaserprodukten wie beispielsweise Holz und Papier sowie Beton, Bitumen und Silikonen. Ziel der Arbeit ist die Formulierungen eines geeigneten Materialmodelles, dass die mathematische Beziehung zwischen Spannungs- und Deformationsprozessen, auf Grundlage künstlicher neuronaler Netze herstellt. Dabei steht die Spannung im funktionalen Zusammenhang mit der Deformationsgeschichte.

2. Generierung synthetischer Materialdaten

In der Modellrheologie werden – analog zu den Schaltbildern der Elektrotechnik – durch geschickte Anordnung mechanischer Grundelemente komplexe Materialmodelle geschaffen. Diese Feder-Dämpfer-Modelle schaffen es, den konstitutiven Zusammenhang viskoelastischer Werkstoffe zu modellieren und dienen als Datengrundlage zur Formulierung eines alternativen Modells basierend auf künstlichen neuronalen Netzen. Für eine algorithmische Erfassung des konstitutiven Zusammenhangs verschiedener viskoelastischer Werkstoffe wurde das verallgemeinertes Maxwell-Modell herangezogen und in eine inkrementelle Darstellung überführt. Die Auswertung der Spannung erfolgt rekursiv für eine ausgewählte Zeitreihe. Dabei wird die Deformationsgeschichte durch die Formulierung des Historyparameters H berücksichtigt.

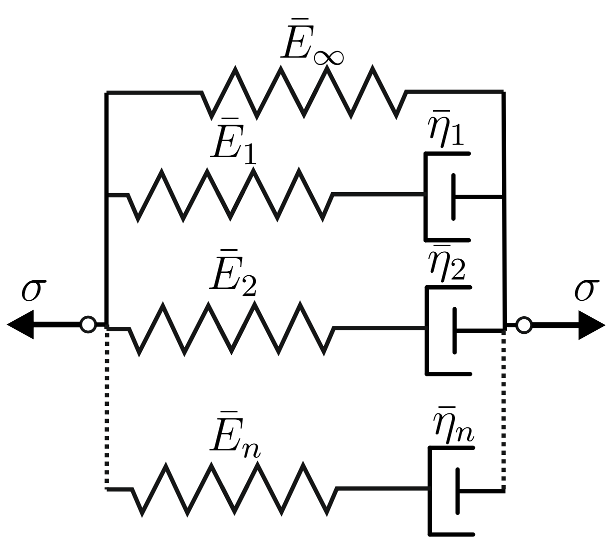

$$\sigma(t_{n+1}) = E_\infty(\varepsilon(t_n) + \Delta\varepsilon) + \sum_{i=1}^{n} e^{-\frac{\Delta t}{\bar{\tau}_i}} H_i(t_n) + \sum_{i=1}^{n} E_i\, \bar{\tau}_i\, \frac{\Delta\varepsilon}{\Delta t}\left[1 - e^{-\frac{\Delta t}{\bar{\tau}_i}}\right]$$

3. Künstliche neuronale Netze als Ersatzmodell

Die Anwendung neuronaler Netze als Materialmodell ist insbesondere dann interessant, wenn eine Modellbildung auf Basis physikalischer Freiheitsgrade nur bedingt oder gar nicht möglich ist. Unter diese Kategorie fällt auch die Modellierung komplexer viskoelastischer Werkstoffe. Die Definition einer mathematischen, physikalisch konsistenten Funktion unter Berücksichtigung aller materialspezifischen Eigenschaften ist aufgrund der Vielzahl an subtilen Einflussgrößen mit erheblichen Schwierigkeiten verbunden.

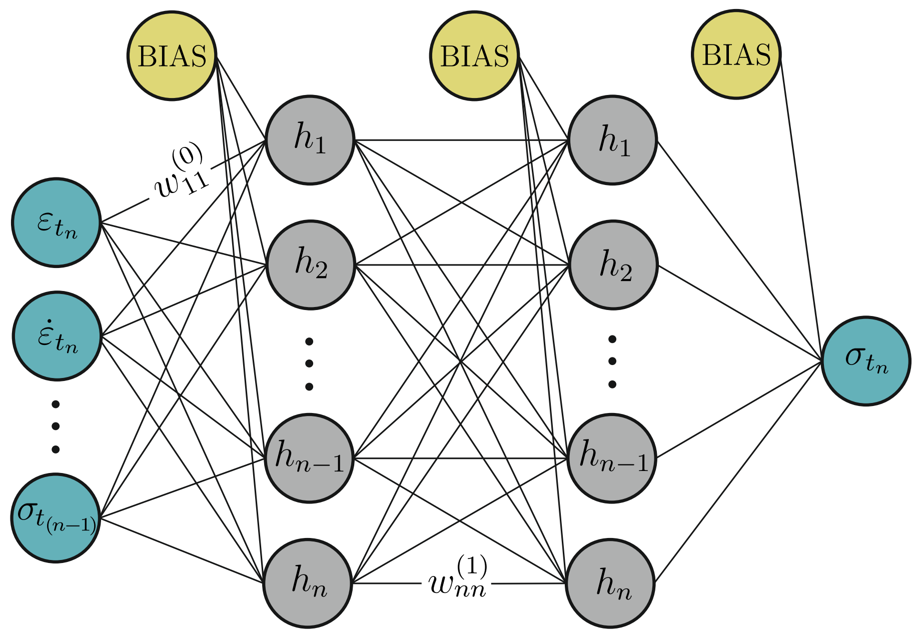

Künstliche neuronale Netze lösen diese Problematik auf anderem Wege. In Anlehnung an das menschliche Gehirn erfassen sie Daten und können aus diesen den funktionalen Zusammenhang generalisieren. Dabei wird der Erfolg des Trainings in der Fehlerfunktion $E(\boldsymbol{w})$ festgehalten, die die Differenz des Soll-Wertes d_j zum Ist-Wert z_j abbildet. Die Aufgabe des Trainingsalgorithmuses ist nun die Anpassung der Gewichte $\boldsymbol{w}$ mit dem Ziel die Fehlerfunktion aller Trainingsdatenpunkte p zu minimieren.

$$E(\boldsymbol{w}) = \frac{1}{2}\sum_{p=1}^{P}\sum_{j=1}^{n(nl)}\left(d_{(p)j} - z_j(\boldsymbol{w})\right)^2 \rightarrow MIN$$

4. Parameterstudie

Zur Erlernung des konstitutiven Zusammenhangs wurde ein synthetisch generierter Datensatz mit Relaxationsversuchen unter Vorgabe konstanter Dehnungungsverläufe erzeugt. Besonderes relevant ist dabei die Wahl geeigneter Eingangs-, bzw. die Berücksichtigung sogenannter Historyparameter, um beim Einsatz von neuronalen Netzen ohne Rückkopplung die bei viskoelastischen Stoffen auftretende Abhängigkeit der Deformationsgeschichte zu berücksichtigen. Zu diesem Zweck wurden Studien zu Trainingsprozessen, Topologie, Gradientenverfahren und Parameteranalyse getätigt. Der nachstehende Versuch wurde stellvertretend für die Versuchsreihe gewählt und zeigt die unterschiedlichen Generalisierungsgrade der künstlichen neuronalen Netze auf Basis verschiedener Eingangsparameter. Die Abbildung zeigt die approximierten Spannungsverläufe der künstlichen neuronalen Netze und den numerisch ermittelten Spannungsverlauf eines zyklischen Versuchs.

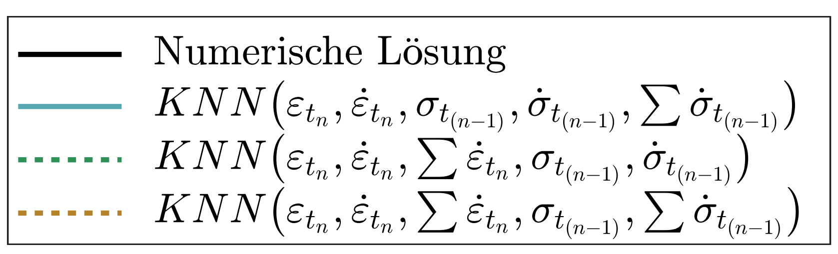

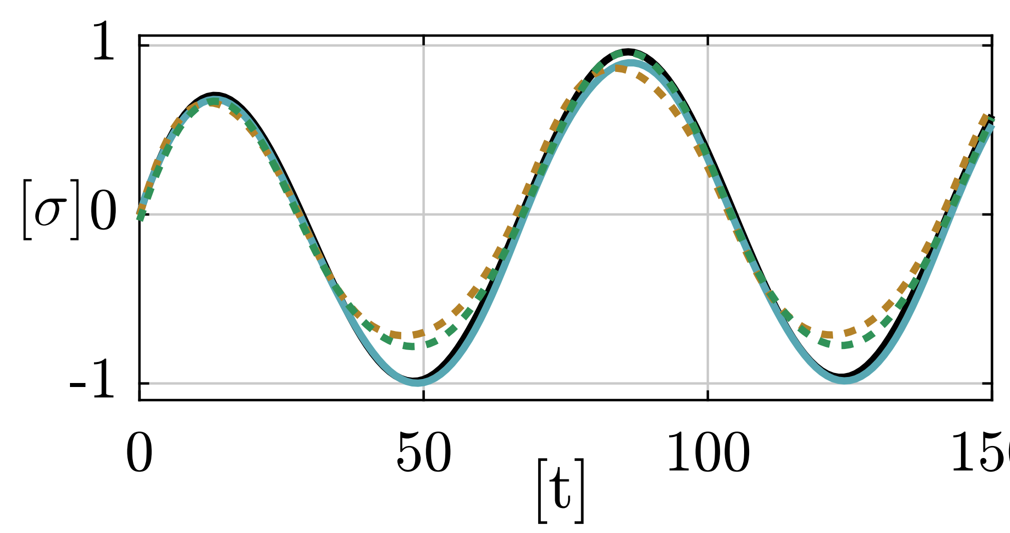

Abbildung: *Zyklischer Versuch*