

Prognose der Kriechdehnung textilverstärkter Tragwerke

Die Strukturantworten von Tragwerken können auf der Basis von Messdaten bzw. numerisch ermittelten Daten prognostiziert und dafür z.B. neuronale Netze eingesetzt werden, siehe [3]. Die neuronalen Netze werden mit Daten trainiert, die aus dem Monitoring stammen. Anschliessend ist eine direkte Prognose der Strukturantwort möglich.

1 Struktur neuronaler Netze

In [4] sind Methoden zur Analyse und Prognose von Zeitreihen mit Fuzzy-Daten zusammengestellt. Für die Prognose der Materialparameter auf der Basis von Messreihen mit Echtzeitdaten wurden Vorgehen mit neuronalen Netzen entwickelt. Die in [1] angewendete Methode erlaubt die Prognose von Strukturantworten oder Materialparametern unter zeitkonstanten Randbedingungen. Durch eine rekursive Anwendung neuronaler Netze wird der Folgewert einer Zeitreihe aus dem aktuellen und den vorangegangenen Werten berechnet, siehe Abb. 1.

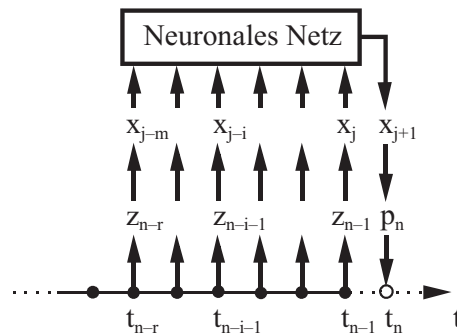


Abbildung 1: Prognoseschema bei rekursiver Netzanwendung

Ein geeigneter Netzwerktyp ist das multi-layer perceptron. In der rekursiven Anwendung wird diese Netzarchitektur als focused time lagged feed-forward perceptron bezeichnet, siehe Abb. 2.

Die Eingangssignale des Netzes sind die $m + 1$ Messwerte x_{j-m} bis x_j der Zeitreihe. Das Ausgangssignal ist der Wert x_{j+1} der Zeitreihe. Für das in Abb. 2 dargestellte multi-layer perceptron wird

$$x_{j+1} = \varphi \left(\sum_{j^{(3)}=1}^{J^{(3)}} \left[w_{j^{(4)}j^{(3)}} \cdot \varphi \left(v_{j^{(3)}} \right) \right] + b_{j^{(4)}} \right) \text{ mit} \quad (1)$$

$$v_{j^{(3)}} = \sum_{j^{(2)}=1}^{J^{(2)}} \left[w_{j^{(3)}j^{(2)}} \cdot \varphi \left(\sum_{j^{(1)}=1}^{J^{(1)}} \left[w_{j^{(2)}j^{(1)}} \cdot x_{j+1-j^{(1)}} \right] + b_{j^{(2)}} \right) \right] + b_{j^{(3)}}$$

berechnet. In Gl. (1) ist $J^{(S)}$ die Anzahl der Neuronen in der Schicht S, $w_{j^{(S)}j^{(S-1)}}$ bezeichnet den Wichtigkeitsfaktor der synaptischen Verbindung von Neuron $j^{(S-1)}$ der Schicht $S-1$ und Neuron $j^{(S)}$ der Schicht S. $b_{j^{(S)}}$ ist der Biaswert des Neuron $j^{(S)}$. Als Aktivierungsfunktionen der Neuronen werden nichtlineare sigmoide Funktionen verwendet, siehe [1] und [2].

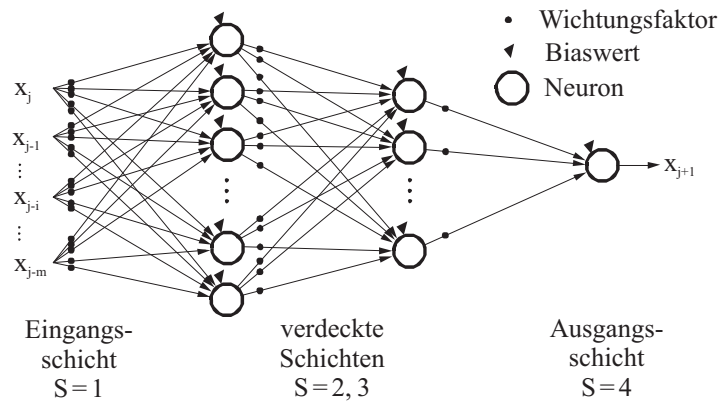


Abbildung 2: Focused time lagged feed-forward perceptron

2 Training und Validierung neuronaler Netze

Das Training neuronaler Netze gelingt durch die Lösung einer Optimierungsaufgabe mit dem *error back-propagation* Algorithmus [2]. Dabei werden die Wichtungsfaktoren und Biaswerte des Netzes schrittweise eingestellt und die Trainingsfehler des Netzes minimiert. Als Fehlermaß wird die Summe der quadratischen Fehler

$$E_{tr} = \sum_{n=m+2}^{N_{tr}} [x_n - d_n]^2 \quad (2)$$

zwischen den prognostizierten Werten x_n und den Messwerten der Zeitreihe d_n über alle Trainingspunkte N_{tr} der Zeitreihe verwendet. Ist der Trainingsfehler hinreichend klein, wird das Training beendet. Mit den bei Trainingsende eingestellten Wichtungsfaktoren und Biaswerten erfolgt die rekursive Mehrschrittprognose, siehe Gl. (1).

Bei der rekursiven Mehrschrittprognose stützt sich die Verifikation und Validierung neuronaler Netze auf Standardverfahren für Zeitreihenprognosen. Die vorliegenden Sequenzen von Daten werden in zwei geeignete Teilsequenzen zerlegt, siehe Abb. 3.

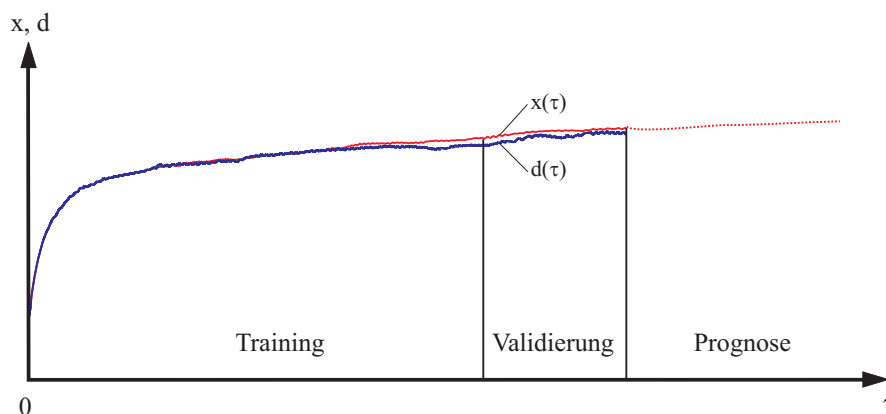


Abbildung 3: Trainings-, Validierungs- und Prognosesequenz

Eine erste Teilsequenz dient dem Training des Netzes. Die darauf aufbauende Prognose wird mit einer zweiten Teilsequenz verglichen. Dieses Vorgehen wird mit unterschiedlicher Wahl der Teilsequenzen wiederholt und erlaubt Rückschlüsse auf die Güte der Prognoseverfahren. Die neuronalen Netze werden dann für die Prognosen über den Beobachtungszeitraum des Monitorings hinaus genutzt.

Durch eine zufällige initiale Belegung der Wichtungsfaktoren und Biaswerte sowie eine zufällige Auswahl der Trainingssequenzen können mehrere neuronale Netze identifiziert werden, die auf einen hinreichend kleinen Trainingsfehler E_{tr} führen. Ein Fehlerkriterium, z.B. $E_{tr} < E_d$, können Netze mit unterschiedlicher Anzahl an Neuronen und verdeckten Schichten erfüllen. Die Berücksichtigung mehrerer Netzantworten bei der Prädiktion liefert Trajektorien eines prognostizierten unscharfen Prozesses.

3 Prognose der Kriechdehnung von Textilbetondehnkörpern

Prognosen der Kriechdehnungen werden nach Verifikation und Validierung neuronaler Netze auf der Basis mäßig langer Messreihen durchgeführt. Diese Prognosen beschreiben die zeitliche Entwicklung der Dehnungen, die entweder unmittelbar Aussagen zum zukünftigen Verformungsverhalten textilverstärkter Tragwerke zulassen oder als Eingangsdaten für numerische Simulationen des Langzeitverhaltens dienen. Aus den Prognoseergebnissen können auch Parameter rheologischer Modelle identifiziert werden.

In Abb. 4 sind Prognosen der Langzeitverformungen eines Textilbetondehnkörpers unter zeitkonstanter Belastung (60% der Kurzzeittraglast) dargestellt, die mit unterschiedlichen Netzen ermittelt wurden. Zum Trainieren, Verifizieren und Validieren der Netze standen aus einem im Teilprojekt B1 durchgeführten Langzeitversuch 28.800 Messwerte über 10 Tage zur Verfügung. Mit der rekursiven Mehrschrittprognose wurden die Kriechdehnungen bis zu einem Jahr prognostiziert.

Die vorliegenden Zeitreihen können als Unschärfe einer Prognose interpretiert werden. Diese Unschärfe kann bei der Weiterverwendung der Ergebnisse berücksichtigt werden.




Abbildung 4: Prognose der Kriechdehnung

Literatur

- [1] Freitag, S.; Beer, M.; Jesse, F.; Weiland, S.: Experimental investigation and prediction of long-term behavior of textile reinforced concrete for strengthening. In: Hegger, J.; Brameshuber, W.; Will, N. (eds.), *1st Intern. RILEM Symposium Textile Reinforced Structures*, RWTH Aachen, 2006, pp. 121–130
- [2] Haykin, S.: *Neural Networks: a comprehensive foundation*. Prentice Hall, Upper Saddle River, 1999
- [3] Kaliske, M.; Graf, W.: Numerisches Tragwerksmonitoring und Prognose des Tragwerkverhaltens. In: Wagner, W. (Hrsg.), *Baustatik-Baupraxis 10*, Universität Karlsruhe (TH), 2008, Bericht, S. 183–192
- [4] Möller, B.; Reuter, U.: *Uncertainty Forecasting in Engineering*. Springer-Verl., Berlin, Heidelberg, New York, 2007