

Prognose des Langzeitverhaltens von Textilbeton-Tragwerken mit rekurrenten neuronalen Netzen*

Steffen Freitag¹, Wolfgang Graf², Michael Kaliske³

Zusammenfassung: Zur Prognose des Langzeitverhaltens textilbetonverstärkter Tragwerke wird ein modellfreies Vorgehen auf Basis rekurrenter neuronaler Netze vorgestellt. Das Vorgehen ermöglicht die Prognose zeitveränderlicher Strukturantworten unter Berücksichtigung der gesamten Belastungsgeschichte. Mit unscharfen Größen aus Messungen an Versuchstragwerken werden rekurrente neuronale Netze trainiert. Anschließend ist die unscharfe Prognose des Tragverhaltens möglich.

Summary: An approach based on recurrent neural networks is introduced, which permits the prediction of the long-term behaviour of textile strengthened structures. Predictions of time-varying structural responses are enabled under consideration of the whole loading history. Recurrent neural networks are trained with uncertain experimental results of test structures. Then, the uncertain prediction of the structural behaviour is feasible.

1 Einleitung

Die Anwendung von Textilbeton zur Verstärkung und Instandsetzung von Stahlbeton-Tragwerken erfordert Kenntnisse über die Langzeitveränderungen unter Designeinwirkungen. Das Langzeitverhalten von Textilbeton-Tragwerken ist von vielen zeitveränderlichen nichtdeterministischen Einwirkungen abhängig, z.B. quasi-statisch oder dynamisch wirkende Belastungen, Temperaturänderungen und Bewitterung. Aus unscharfen zeitveränderlichen Einwirkungen resultieren unscharfe zeitveränderliche Verformungen und Lastumlagerungen.

Aus Versuchen können Informationen in Hinblick auf zeitabhängige Veränderungen der Tragwerke nur über kurze Zeiträume effizient erhalten werden. Mit numerischen Methoden gelingt

*Dies ist eine begutachtete Veröffentlichung./This is a peer-reviewed paper.

Online verfügbar/Online available: [urn:nbn:de:bsz:14-ds-1244048026002-79164](https://nbn-resolving.org/urn:nbn:de:bsz:14-ds-1244048026002-79164)

¹Dipl.-Ing., Institut für Statik und Dynamik der Tragwerke, Technische Universität Dresden

²Prof. Dr.-Ing., Institut für Statik und Dynamik der Tragwerke, Technische Universität Dresden

³Prof. Dr.-Ing. habil., Institut für Statik und Dynamik der Tragwerke, Technische Universität Dresden

es, aus diesen Informationen die Langzeitveränderungen zu prognostizieren, siehe z.B. [4]. In [5] wird ein Konzept zur numerischen Langzeitprognose der Kriechverformungen von Textilbetondehnkörpern unter zeitkonstanten Randbedingungen gezeigt. Dabei werden neuronale Netze zur rekursiven Mehrschrittprognose von Langzeitverformungen eingesetzt. Die Messwerte zum Trainieren der Netze werden aus Versuchen unter konstanter Temperatur und Luftfeuchte (Klimakammer) erhalten.

Für die numerische Prognose des Langzeitverhaltens von Textilbeton-Tragwerken unter zeitveränderlichen Randbedingungen wird ein neues Vorgehen auf der Basis neuronaler Netze vorgestellt. Dabei werden rekurrente neuronale Netze [14] mit unscharfen Daten trainiert, die aus dem Monitoring von Versuchstragwerken stammen. Die Datenunschärfe wird mit dem Unschärfemodell Fuzziness beschrieben. Eingabegrößen der rekurrenten neuronalen Netze sind diskretisierte Fuzzy-Prozesse der Einwirkungen. Aus diesen unscharfen Eingabegrößen werden Fuzzy-Prozesse der Strukturantworten prognostiziert. Mit rekurrenten neuronalen Netzen werden in jedem Zeitschritt Fuzzy-Eingabegrößen auf Fuzzy-Ausgabegrößen unter Berücksichtigung der gesamten Belastungsgeschichte abgebildet. Eine numerisch effiziente Lösung dieser mathematischen Abbildung gelingt durch die α -Level Diskretisierung der Fuzzy-Größen [10] und intervallararithmetische Operationen. Intervalle und deterministische Größen können als Sonderfälle von Fuzzy-Größen, siehe Bild 1, behandelt werden.

Die Anwendung der entwickelten Algorithmen wird für die Prognose der Langzeitverformung eines mit Textilbeton verstärkten Stahlbeton-Tragwerks gezeigt.

2 Monitoring zeitveränderlicher Tragwerksparameter

Zeitveränderliche Tragwerksparameter können durch Tragwerksmonitoring ermittelt werden. Für eine realitätsnahe Beschreibung der beobachteten Phänomene muss neben der physikalischen Interpretation der Messwerte die Datenunschärfe berücksichtigt werden. Datenunschärfe ist beispielsweise bei der Wiederholung eines Versuchs unter scheinbar identischen Randbedingungen vorhanden. Bei der Diskretisierung deterministischer Prozesse können unscharfe Daten erhalten werden. Zur Charakterisierung der Unschärfe wird das Unschärfemodell Fuzziness verwendet.

2.1 Fuzzy-Prozesse

Für die numerische Verarbeitung werden die durch Tragwerksmonitoring ermittelten Messwerte aufbereitet. Die Unschärfe zeitveränderlicher Messwerte wird als Fuzzy-Prozess modelliert, siehe [9]. Ein Fuzzy-Prozess ist mit

$$\tilde{x}(\tau) = \{\tilde{x}_\tau = \tilde{x}(\tau) \mid \forall \tau \mid \tilde{x}_\tau \in \mathbf{F}(\mathbf{X})\} \quad (1)$$

definiert. Zu jedem Zeitpunkt τ werden unscharfe Funktionswerte $\tilde{x}(\tau)$ erhalten, die Elemente der Menge $\mathbf{F}(\mathbf{X})$ aller unscharfen Größen sind. Diese unscharfen Funktionswerte sind Fuzzy-Größen, d.h. mit Zugehörigkeitsfunktionen $\mu(x)$ bewertete Mengen. Der Support $B(\tilde{x})$ einer

Fuzzy-Größe ist ein Intervall, das alle Elemente mit der Zugehörigkeit $\mu(x) > 0$ enthält, siehe Bild 2. Außerhalb dieses Intervalls ist die Zugehörigkeitsfunktion $\mu(x) = 0$. Die Intervallgrenzen des Supports werden durch $\mu(x) \rightarrow 0+$ erhalten.

Konvexe Fuzzy-Größen können in Fuzzy-Zahlen und Fuzzy-Intervalle unterteilt werden, siehe [9]. Während bei Fuzzy-Zahlen für den Wert der Zugehörigkeitsfunktion $\mu(x) = 1$ genau ein deterministisches Argument x (Gipfelpunkt) existiert, wird bei Fuzzy-Intervallen für $\mu(x) = 1$ ein Gipfelintervall erhalten, siehe Bild 1.




Bild 1: Fuzzy-Größen
Figure 1: Fuzzy quantities

Sind die Zugehörigkeitsfunktionen zwischen $\mu(x) \rightarrow 0+$ und $\mu(x) = 1$ linear, werden Fuzzy-Dreieckzahlen als Sonderfall der Fuzzy-Zahlen erhalten. Die Bezeichnung einer Fuzzy-Dreieckzahl $\tilde{x} = \langle x_1; x_2; x_3 \rangle$ mit $\mu(x_1) \rightarrow 0+$, $\mu(x_2) = 1$ und $\mu(x_3) \rightarrow 0+$ enthält alle diese spezielle Fuzzy-Größe charakterisierenden Werte.

2.2 Diskretisierung der Fuzzy-Prozesse

Für die numerische Prognose des Langzeitverhaltens textilbetonverstärkter Tragwerke werden die Fuzzy-Prozesse diskretisiert, d.h. es erfolgt eine Zeitschrittdiskretisierung und eine Diskretisierung der Zugehörigkeitsfunktionen der Fuzzy-Größen.

Im Zeitbereich werden die Fuzzy-Prozesse in äquidistante Zeitschritte $[n = 1, \dots, N]$ diskretisiert. Damit sind zu jedem Zeitpunkt ${}^{[n]}\tau$ Fuzzy-Größen ${}^{[n]}\tilde{x}$ verfügbar. Der Diskretisierungsalgorithmus ist von der Zeitschrittlänge des Monitorings abhängig.

- Ist die Zeitschrittlänge im Monitoring identisch der diskretisierten Zeitschrittlänge, können die Daten aus dem Monitoring direkt für die numerische Prognose verwendet werden.
- Sind die Fuzzy-Prozesse durch unscharfe Messwerte gegeben, die nicht den Zeitpunkten der Diskretisierung entsprechen, können die Fuzzy-Größen ${}^{[n]}\tilde{x}$ durch Interpolation aus vorangegangenen und nachfolgenden Messwerten approximiert werden.

Die Zugehörigkeitsfunktionen $\mu([n]\tilde{x})$ der Fuzzy-Größen $[n]\tilde{x}$ werden in $s = 1, \dots, S$ α -Level diskretisiert, siehe [10]. Für jedes α -Level wird ein zusammenhängendes Intervall $[\alpha_s l x; \alpha_s r x]$ mit dem linken Rand

$$[\alpha_s l x] = \min [x \in [n]\mathbf{X} \mid \mu([n]x) \geq \alpha_s] \quad (2)$$

und dem rechten Rand

$$[\alpha_s r x] = \max [x \in [n]\mathbf{X} \mid \mu([n]x) \geq \alpha_s] \quad (3)$$

erhalten, siehe Bild 2.




Bild 2: α -Level Diskretisierung einer Fuzzy-Größe

Figure 2: α -level discretization of a fuzzy quantity

Das Intervall $[\alpha_1 l x; \alpha_1 r x]$ von α -Level $\alpha_1 = 0$ entspricht dem Support $B([n]\tilde{x})$ der diskretisierten Fuzzy-Größe. Das Gipfelintervall wird für $\alpha_S = 1,0$ erhalten. Bei Fuzzy-Zahlen gilt für den Gipfelpunkt $[\alpha_S l x] = [\alpha_S r x]$.

3 Neuronale Netze für Fuzzy-Größen

Künstliche neuronale Netze sind informationsverarbeitende Systeme, die aus Neuronen und synaptischen Verbindungen bestehen. In Struktur und Funktionsweise sind neuronale Netze vom menschlichen Gehirn adaptiert. Neuronale Netze sind lernfähige Systeme. In [7] und [14] sind unterschiedliche Typen neuronaler Netze beschrieben. Ein Überblick möglicher Anwendungen neuronaler Netze im Bauingenieurwesen ist in [1] gegeben. Die meisten Anwendungen neuronaler Netze basieren auf einer *feed-forward* Architektur. In [11] werden beispielsweise neuronale Netze mit *feed-forward* Architektur zur Prognose von Zeitreihen mit Fuzzy-Daten eingesetzt. Zur unscharfen Prognose des Langzeitverhaltens textilbetonverstärkter Tragwerke werden in diesem Beitrag rekurrente neuronale Netze für Fuzzy-Größen entwickelt.

Die Prognose von Strukturantworten mit rekurrenten neuronalen Netzen kann als mathematische Abbildung interpretiert werden. Liegen die zeitveränderlichen Struktureinwirkungen als diskretisierte Fuzzy-Prozesse vor, kann mit deterministischen Netzparametern eine scharfe Abbildung der $j = 1, \dots, J$ zeitveränderlichen Einwirkungen $^{[n]}\tilde{x}_j$ auf $k = 1, \dots, K$ zeitveränderliche Strukturantworten $^{[n]}\tilde{z}_k$ des Tragwerks erfolgen. Bei dieser Abbildung wird die Datenunschärfe der Messwerte berücksichtigt. Das neuronale Netz wird als deterministische Grundlösung betrachtet. Ein Sonderfall ist die Abbildung von deterministischen Einwirkungsprozessen auf deterministische Prozesse der Strukturantworten, siehe z.B. [12].

3.1 Netzarchitektur

Bei der Prognose von Strukturantworten textilbewehrter Stahlbeton-Tragwerke ist zeitabhängiges Materialverhalten zu berücksichtigen. Die Berücksichtigung der Geschichtsabhängigkeit der aktuellen Tragwerksantwort gelingt mit sogenannten partiell rekurrenten neuronalen Netzen. In Bild 3 ist der Aufbau eines partiell rekurrenten neuronalen Netzes für die Prognose von Fuzzy-Größen dargestellt. Das Netz besteht aus der Eingabeschicht, $(M - 2)$ verdeckten Schichten und der Ausgabeschicht. Die Geschichtsabhängigkeit der aktuellen Strukturantwort wird durch zeitverzögerte interne Rückkopplungen berücksichtigt.

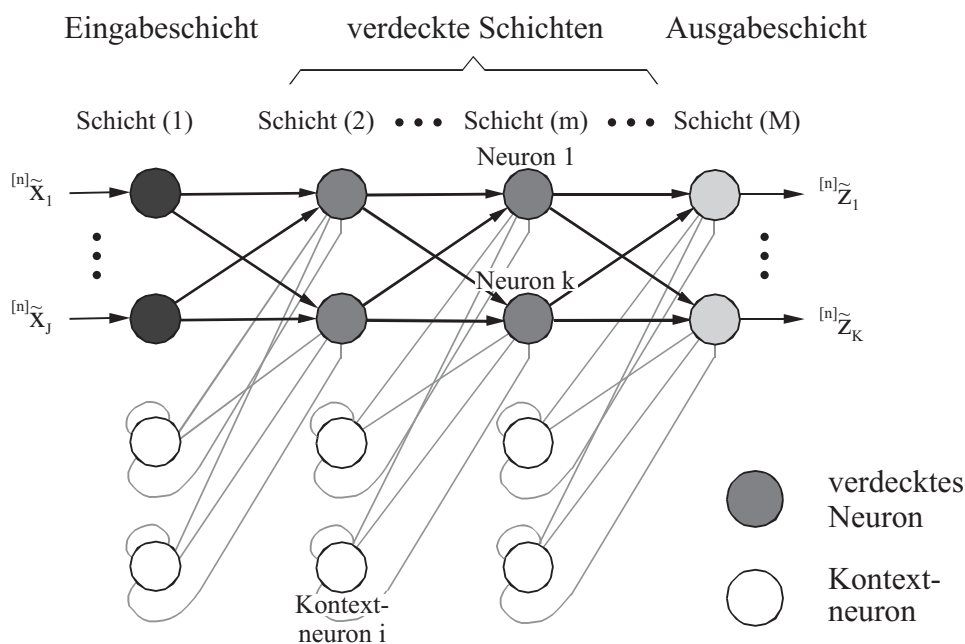


Bild 3: Rekurrentes neuronales Netz

Figure 3: Recurrent neural network

Die unscharfe Tragwerksantwort $^{[n]}\tilde{z}_k$, mit $k = 1, \dots, K$ wird im Zeitschritt $[n]$ unter Berücksichtigung der aktuellen unscharfen Einwirkungen $^{[n]}\tilde{x}_j$, mit $j = 1, \dots, J$ und der gesamten Belastungsgeschichte durch das partiell rekurrente neuronale Netz prognostiziert, siehe Bild 3.

3.2 Prognoseschritt

Die Signalverarbeitung partiell rekurrenter neuronaler Netze erfolgt im Prognoseschritt von den Neuronen der Eingabeschicht zu den Neuronen der Ausgabeschicht, siehe Bild 3.

In jedem Zeitschritt werden in den Eingabeneuronen die unscharfen Eingabegrößen $^{[n]}\tilde{x}_j$ skaliert. Die skalierten Fuzzy-Größen $^{[n]}\tilde{x}_j^{(1)}$ werden an die erste verdeckte Schicht ($m = 2$) übergeben.

In Neuron k der Schicht (m) mit ($m = 2, \dots, M$) wird aus den unscharfen Ausgabesignalen $^{[n]}\tilde{x}_j^{(m-1)}$, mit $j = 1, \dots, J^{(m-1)}$ der vorherigen Schicht und den unscharfen Kontextsignalen $^{[n]}\tilde{y}_i^{(m)}$, mit $i = 1, \dots, I^{(m)}$ das unscharfe Ausgabesignal

$$^{[n]}\tilde{x}_k^{(m)} = \varphi^{(m)} \left(\sum_{j=1}^{J^{(m-1)}} \left[^{[n]}\tilde{x}_j^{(m-1)} \cdot w_{kj}^{(m)} \right] + \sum_{i=1}^{I^{(m)}} \left[^{[n]}\tilde{y}_i^{(m)} \cdot c_{ki}^{(m)} \right] + b_k^{(m)} \right) \quad (4)$$

berechnet. In Gl. (4) ist $w_{kj}^{(m)}$ der Wichtungsfaktor der synaptischen Verbindung zwischen Neuron j der Schicht ($m - 1$) und Neuron k der Schicht (m). Der Faktor $c_{ki}^{(m)}$ in Gl. (4) ist das Kontextgewicht zwischen Kontextneuron i und Neuron k . Mit $b_k^{(m)}$ wird der Biaswert von Neuron k bezeichnet. Die Anzahl der synaptischen Verbindungen $J^{(m-1)}$ entspricht der Neuronenanzahl in der vorherigen Schicht ($m - 1$). Mit $I^{(m)}$ ist die Anzahl der Kontextneuronen gegeben.

Die gewichteten unscharfen Eingabesignale in Neuron k werden mit einer Aktivierungsfunktion $\varphi^{(m)} \left(^{[n]}\tilde{\nu}_k^{(m)} \right)$ verarbeitet, siehe Gl. (4). In den Neuronen der verdeckten Schichten ($m = 2, \dots, M - 1$) werden nichtlineare Aktivierungsfunktionen

$$\varphi^{(m)} \left(^{[n]}\tilde{\nu}_k^{(m)} \right) = a \cdot \operatorname{arsinh} \left(^{[n]}\tilde{\nu}_k^{(m)} \right) \quad (5)$$

verwendet, um aus dem Argument $^{[n]}\tilde{\nu}_k^{(m)}$ das unscharfe Ausgabesignal $^{[n]}\tilde{x}_k^{(m)}$ zu berechnen. In den Neuronen der Ausgabeschicht (M) ist die Signalverarbeitung linear.

$$\varphi^{(M)} \left(^{[n]}\tilde{\nu}_k^{(M)} \right) = a \cdot ^{[n]}\tilde{\nu}_k^{(M)} \quad (6)$$

Über den Parameter a in den Gln. (5) und (6) kann der Anstieg der monotonen Aktivierungsfunktionen variiert werden. In den Ausgabeneuronen werden die Netzantworten $^{[n]}\tilde{x}_k^{(M)}$ in den Wertebereich der unscharfen Strukturantworten $^{[n]}\tilde{z}_k$ transformiert.

In den Kontextneuronen werden die Ausgabesignale der Neuronen in Schicht (m) zu Eingabesignalen für den nachfolgenden Zeitschritt $[n + 1]$ aufbereitet. Das Signal von Kontextneuron i wird mit

$$^{[n+1]}\tilde{y}_i^{(m)} = ^{[n]}\tilde{x}_i^{(m)} \cdot \gamma_i^{(m)} + ^{[n]}\tilde{y}_i^{(m)} \cdot \lambda_i^{(m)} \quad (7)$$

erhalten. Die Rückkopplungsfaktoren $\gamma_i^{(m)}$ in Gl. (7) sind im Intervall $[0; 1]$ definiert. Für $\gamma_i^{(m)} = 0$ wird keine Geschichte im Kontextneuron i gespeichert. Sind alle Rückkopplungsfaktoren im rekurrenten neuronalen Netz gleich Null, wird keine Geschichtsabhängigkeit bei der Netzausgabe berücksichtigt. Damit wird ein *feed-forward* Netz als Sonderfall des partiell rekurrenten neuronalen Netzes erhalten. Der direkte Rückkopplungsfaktor $\lambda_i^{(m)}$ von Kontextneuron i wichtet den Einfluss des aktuellen Kontextausgabesignals $^{[n]}\tilde{y}_i^{(m)}$ auf die Kontextausgabe im nachfolgenden Zeitschritt. Die direkten Rückkopplungsfaktoren sind ebenfalls im Bereich $[0; 1]$ definiert.

Im ersten Zeitschritt $[n = 1]$ sind alle Kontextsignale $^{[1]}\tilde{y}_i^{(m)}$ durch eine initiale Belegung gegeben. Für den Fall $^{[1]}\tilde{y}_i^{(m)} = 0$ für alle $i = 1, \dots, I^{(m)}$ und $m = 2, \dots, (M)$ entfallen im ersten Zeitschritt die zweiten Terme in Gl. (4). In den folgenden Zeitschritten $[n > 1]$ werden die Kontextsignale mit Gl. (7) berechnet.

Zur numerischen Verarbeitung von Fuzzy-Größen mit rekurrenten neuronalen Netzen wird die deterministische Signalverarbeitung aus [12] erweitert. Die Erweiterung gelingt mit der in Abschnitt 2 beschriebenen α -Level Diskretisierung der Fuzzy-Größen und intervallararithmetischen Berechnungen auf jedem α -Level.

3.3 Trainingsschritt

Im Trainingsschritt werden die Parameter rekurrenter neuronaler Netze eingestellt. Das Ziel des Netztrainings ist eine möglichst realitätsnahe Prognose der unscharfen Tragwerksantwort $^{[n]}\tilde{z}_k$ infolge der unscharfen Einwirkungen $^{[n]}\tilde{x}_j$ für alle Zeitpunkte $[n = 1, \dots, N]$. Dazu werden die Fuzzy-Ausgabesignale des rekurrenten neuronalen Netzes $^{[n]}\tilde{x}_k^{(M)}$ mit den unscharfen skalierten Messwerten $^{[n]}\tilde{d}_k$ aus dem Tragwerksmonitoring verglichen. Zur Bewertung des Prognosefehlers rekurrenter neuronaler Netze wird ein Abstandsmaß

$$^{[n]}E = \frac{1}{2} \sum_{k=1}^{K^{(M)}} \left\{ \sum_{s=1}^S \left[\left(\begin{smallmatrix} [n] \\ \alpha_{sl} \end{smallmatrix} d_k - \begin{smallmatrix} [n] \\ \alpha_{sl} \end{smallmatrix} x_k^{(M)} \right)^2 + \left(\begin{smallmatrix} [n] \\ \alpha_{sr} \end{smallmatrix} d_k - \begin{smallmatrix} [n] \\ \alpha_{sr} \end{smallmatrix} x_k^{(M)} \right)^2 \right] \right\} \quad (8)$$

für Fuzzy-Größen eingeführt. Dieses deterministische Fehlerkriterium berücksichtigt die Fehler der linken und rechten Ränder jedes α -Levels im Zeitschritt $[n]$ entsprechend der in Abschnitt 2 eingeführten Diskretisierung.

Zur Kontrolle der Prognosefähigkeit des Netzes werden alle verfügbaren Messreihen in Trainings- und Validierungsreihen separiert. Wird nur eine Messreihe berücksichtigt, werden die Zeitschritte $[n = 1, \dots, N_{tr}]$ zum Trainieren und die Zeitschritte $[n = N_{tr} + 1, \dots, N]$ zum Validieren des Netzes verwendet. Der gemittelte Gesamttrainingsfehler wird aus

$$E_{tr}^{av} = \frac{1}{N_{tr}} \sum_{n=1}^{N_{tr}} [^{[n]}E] \quad (9)$$

erhalten.

Zur Einstellung der Netzparameter wird eine Optimierungsaufgabe formuliert. Dabei ist E_{tr}^{av} gemäß Gl. (9) zu minimieren. Die Lösung dieser Optimierungsaufgabe kann mit unterschiedlichen Strategien erfolgen. In [7] und [14] werden einige Trainingsstrategien vorgestellt. Für die rekursive Signalverarbeitung mit Fuzzy-Größen wird ein modifizierter *backpropagation* Algorithmus nach [12] entwickelt.

3.4 Validierung

Nach jedem Trainingsschritt wird eine Netzvalidierung durchgeführt. Der gemittelte Gesamtvalidierungsfehler wird mit

$$E_v^{av} = \frac{1}{N - N_{tr}} \sum_{n=N_{tr}+1}^N [{}^{[n]}E] \quad (10)$$

berechnet. Mit den Gln. (9) und (10) kann ein Fehlermonitoring durchgeführt werden, um die Prognosequalität des rekurrenten neuronalen Netzes während des Trainings zu überwachen.

Sind Trainings- und Validierungsfehler hinreichend klein, wird das Training beendet. Sollte das gewählte Netz nicht zur gewünschten Prognosequalität führen, wird die Netzarchitektur verändert. Die Ermittlung der Netzarchitektur kann mit numerischen Methoden, siehe z.B. [2], [3] oder [8], erfolgen.

4 Prognose der Langzeitverformung eines mit Textilbeton verstärkten Tragwerks

Die neu entwickelten rekurrenten neuronalen Netze für Fuzzy-Größen werden zur Prognose der Langzeitverformung einer mit Textilbeton verstärkten Stahlbetonplatte angewendet. Die Prognose basiert auf Messwerten am Tragwerk über einen Zeitraum von 286 Tagen. In Bild 4 sind Geometrie und Belastung des untersuchten Tragwerks dargestellt.




Bild 4: Geometrie des untersuchten Tragwerks

Figure 4: Geometry of the investigated structure

Die Stahlbetonplatte ist auf der Unterseite mit einer Textilbetonschicht verstärkt. Die Verstärkungsschicht besteht aus Feinbeton und zwei Lagen Carbonfasertextil, siehe [13]. Das Aufbringen der Belastung (Kurzzeittragverhalten) der textilbetonverstärkten Stahlbetonkonstruktion wird mit numerischen Modellen unter Berücksichtigung von Unschärfe simuliert, siehe z.B. [6].

In diesem Beispiel wird die Durchbiegung in Plattenmitte als zu prognostizierender Fuzzy-Tragwerksprozess gewählt. Die Daten für das Training eines rekurrenten neuronalen Netzes werden durch ein Tragwerksmonitoring am Versuchstragwerk erhalten. Die Messwerte der Durchbiegung in Plattenmitte, der Umgebungstemperatur und der Luftfeuchte stehen in [13] zur Verfügung. Diese Rohdaten werden zur Verarbeitung im neuronalen Netz in äquidistante Zeitschritte $\Delta\tau = 1\text{d}$ diskretisiert.

Die Messwerte werden zu jedem diskreten Zeitpunkt als Fuzzy-Dreieckzahl modelliert. Der linke Rand des Supports wird aus dem Minimum des Messwerts im vorangegangenen Zeitschritt erhalten. Das Maximum des Messwerts im vorangegangenen Zeitschritt liefert den rechten Rand des Supports. Der Zugehörigkeitswert $\mu = 1$ der Fuzzy-Dreieckzahl entspricht dem Messwert zum Zeitpunkt τ . Die aus der beschriebenen Diskretisierung resultierenden Fuzzy-Prozesse der Temperatur $\tilde{T}(\tau)$, der relativen Luftfeuchte $\tilde{f}(\tau)$ und der Verschiebung $\tilde{w}(\tau)$ sind in den Bildern 5, 6 und 7 dargestellt.

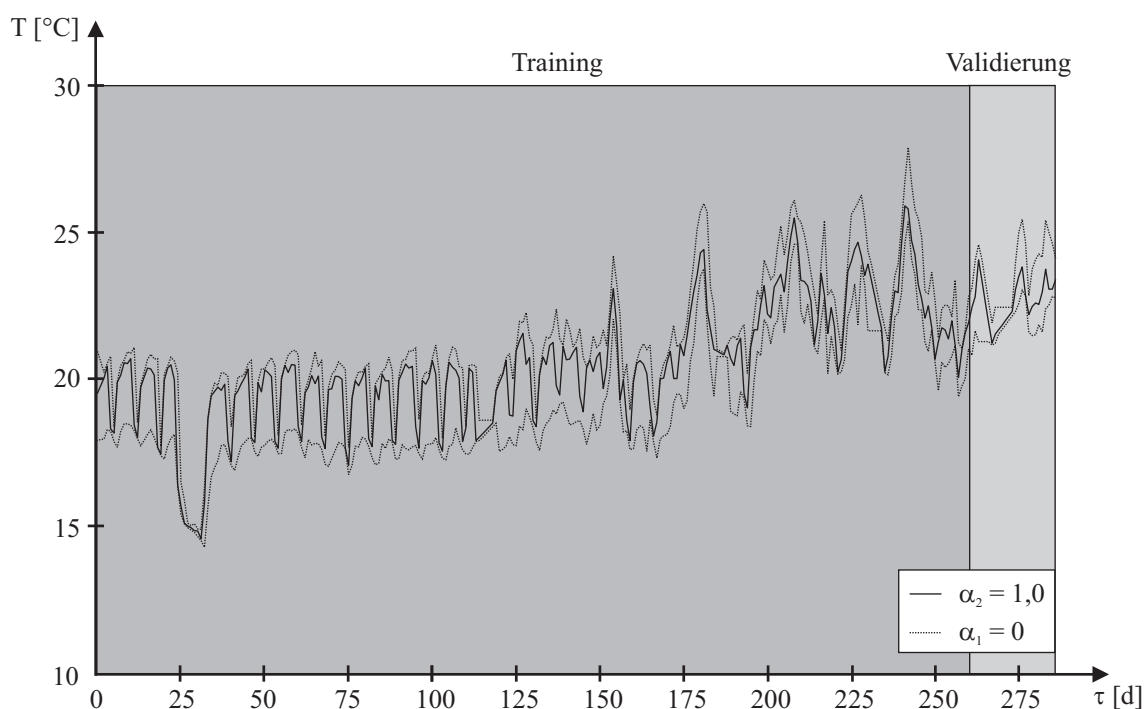


Bild 5: Temperaturprozess $\tilde{T}(\tau)$
Figure 5: Temperature process $\tilde{T}(\tau)$




Bild 6: Luftfeuchteprozess $\tilde{f}(\tau)$

Figure 6: Humidity process $\tilde{f}(\tau)$

Die Belastung des Tragwerks, siehe Bild 4, wird als unscharfer Lastprozess $\tilde{P}(\tau)$ modelliert.

$$\tilde{P}(\tau) = \begin{cases} 0, & \text{wenn } \tau = 0 \\ \langle 44, 5; 45, 4; 46, 3 \rangle, & \text{wenn } \tau > 0 \end{cases} \quad (11)$$

Die Fuzzy-Prozesse $\tilde{P}(\tau)$, $\tilde{T}(\tau)$ und $\tilde{f}(\tau)$ sind die unscharfen Einwirkungen des Tragwerks. In jedem diskreten Zeitpunkt sind die entsprechenden Fuzzy-Dreieckzahlen Eingabegrößen eines rekurrenten neuronalen Netzes. Aus diesen Eingabegrößen wird der Fuzzy-Verschiebungsprozess $\tilde{w}(\tau)$ unter Berücksichtigung der gesamten Belastungsgeschichte berechnet.

Die ersten 260 Zeitschritte der Fuzzy-Prozesse werden zum Training eines rekurrenten neuronalen Netzes verwendet. Die Anzahl der verdeckten Schichten und Neuronen wurde mit einem adaptiven Vorgehen gefunden. Das Netz besteht aus ($M = 5$) Schichten. Die Netzarchitektur wird mit $3 - 6 - 4 - 4 - 1$ bezeichnet, d.h. drei Eingabeneuronen, drei verdeckte Schichten (mit $J^{(2)} = 6$, $J^{(3)} = 4$ und $J^{(4)} = 4$ Neuronen) und ein Ausgabeneuron. Zur Berücksichtigung der Belastungsgeschichte ist jedem verdeckten Neuron und dem Ausgabeneuron ein Kontextneuron zugeordnet. Das Training des Netzes erfolgt mit dem in Abschnitt 3 beschriebenen Vorgehen.

Zur Validierung des rekurrenten neuronalen Netzes werden die 26 folgenden Zeitschritte verwendet. In Bild 7 sind die diskretisierten Messwerte und die Prognose mit dem trainierten und

validierten Netz dargestellt. Die prognostizierten Fuzzy-Größen stimmen im Trainings- und Validierungsbereich gut mit den diskretisierten Messwerten überein.

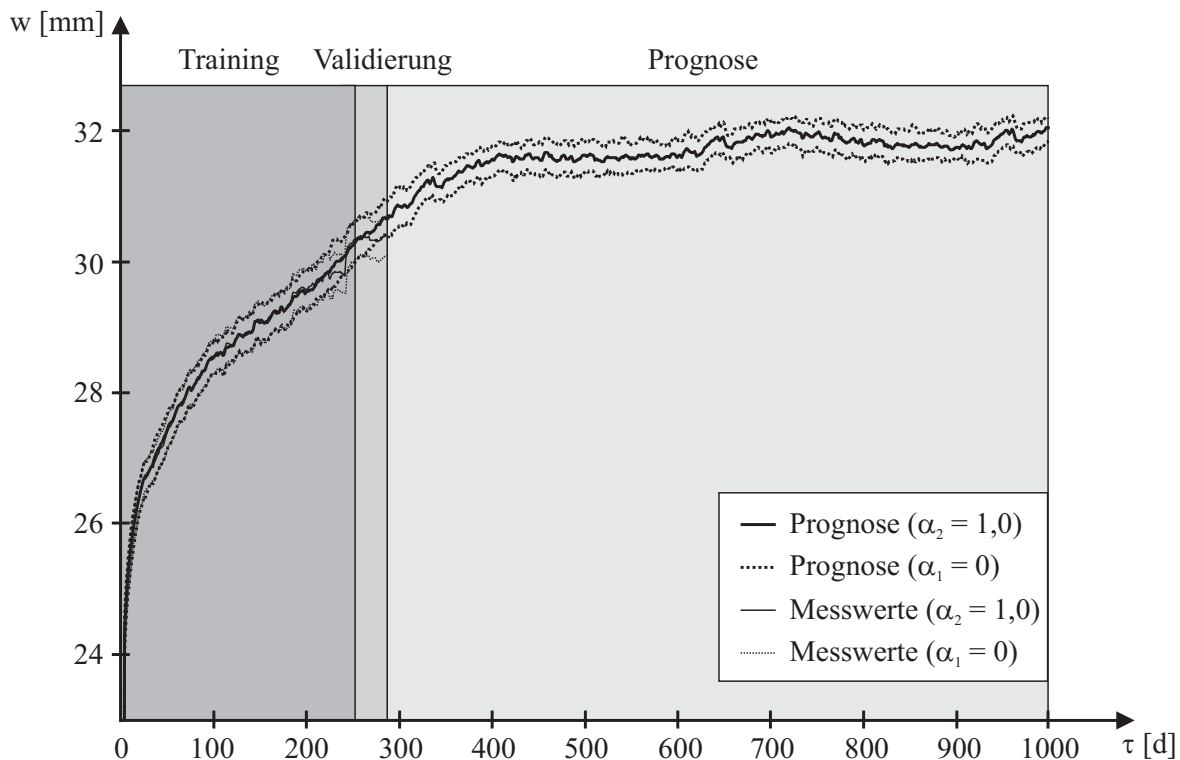


Bild 7: Verschiebung $\tilde{w}(\tau)$, Messwerte und Prognose des neuronalen Netzes

Figure 7: Displacement $\tilde{w}(\tau)$, measured data and neural network prediction

Nach dem Training und der Validierung des rekurrenten neuronalen Netzes kann das Verformungsverhalten des Tragwerks prognostiziert werden. Die Umgebungstemperatur und die Luftfeuchte sind als Messwerte für 314 Tage verfügbar. Für die Prognose des weiteren Verformungsverhaltens wurde eine periodische Wiederholung des Feuchte- und Temperaturprozesses angenommen. In Bild 7 ist die prognostizierte Verschiebung für 1000 Tage dargestellt.

In zukünftigen Anwendungen könnten rekurrente neuronale Netze für Fuzzy-Größen mit mehreren zeitveränderlichen Lastprozessen trainiert werden, um verschiedene unscharfe Prozesse zu prognostizieren. Dabei können sowohl unterschiedliche Lastniveaus als auch verschiedene Be- und Entlastungsprozesse berücksichtigt werden. Die Prognose der weiteren Feuchte- und Temperaturzustände könnte mit Methoden nach [11] erfolgen.

Danksagung

Die Autoren danken der Deutschen Forschungsgemeinschaft für die finanzielle Unterstützung der Forschung im Rahmen des Sonderforschungsbereiches 528 „Textile Bewehrungen zur bautechnischen Verstärkung und Instandsetzung“.

5 Literatur

- [1] ADELI, H.: Neural networks in civil engineering: 1989-2000. *Computer-Aided Civil and Infrastructure Engineering* 16 (2001), S. 126–142
- [2] ARIFOVIC, J.; GENÇAY, R.: Using genetic algorithms to select architecture of a feed-forward artificial neural network. *Physica A* 289 (2001), S. 574–594
- [3] BERNARDOS, P.G.; VOSNIAKOS, G.-C.: Optimizing feedforward artificial neural network architecture. *Engineering Application of Artificial Intelligence* 20 (2007), S. 365–382
- [4] FREITAG, S.; BEER, M.; GRAF, W.; KALISKE, M.: Lifetime prediction using accelerated test data and neural networks. *Computers & Structures* (2009) (zur Veröffentlichung angenommen)
- [5] 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.): *Proceedings of the 1st International RILEM Symposium on textile reinforced concrete, September 6-7, 2006, Aachen*. Bagnaux: RILEM, 2006, S. 121–130
- [6] GRAF, W.; MÖLLER, B.; HOFFMANN, A.; SICKERT, J.-U.; STEINIGEN, F.: Analysis of textile reinforced concrete structures under consideration of non-traditional uncertainty models. *Engineering Structures* 29 (2007), S. 3420–3431
- [7] HAYKIN, S.: *Neural Networks: a comprehensive foundation*. 2. Edt., Upper Saddle River: Prentice Hall, 1999
- [8] MA, L.; KHORASANI, K.: A new strategy for adaptively constructing multilayer feed-forward neural networks. *Neurocomputing* 51 (2003), S. 361–385
- [9] MÖLLER, B.; BEER, M.: *Fuzzy Randomness – Uncertainty in Civil Engineering and Computational Mechanics*. Berlin: Springer, 2004
- [10] MÖLLER, B.; GRAF, W.; BEER, M.: Fuzzy structural analysis using α -level optimization. *Computational Mechanics* 26 (2000), S. 547–565
- [11] MÖLLER, B.; REUTER, U.: *Uncertainty Forecasting in Engineering*. Berlin: Springer, 2007
- [12] OESER, M.; FREITAG, S.: Modeling of materials with fading memory using neural networks. *International Journal for Numerical Methods in Engineering* 78 (2009), S. 843–862
- [13] WEILAND, S.: *Interaktion von Betonstahl und textiler Bewehrung bei der Biegeverstärkung mit textilbewehrtem Beton*. Institut für Massivbau, Technische Universität Dresden, Dissertation (in Vorbereitung)
- [14] ZELL, A.: *Simulation neuronaler Netze*. Bonn, Paris: Addison-Wesley, 1996