

Theorie und Numerik von Deep Material Networks für mehrskalige inelastische Materialien

Lukas Lienhard

1. Einführung und Motivation

Die Simulation und Modellierung von Werkstoffen mit einem komplexen mikrostrukturellen Aufbau ist durch die verfügbaren Rechenkapazitäten sehr limitiert. Durch die Anwendung eines Deep Material Networks (DMN) als Modellreduktionsverfahren können rechenintensive Mehrskalen-Simulationen wie bspw. mit FE^2 ersetzt werden.

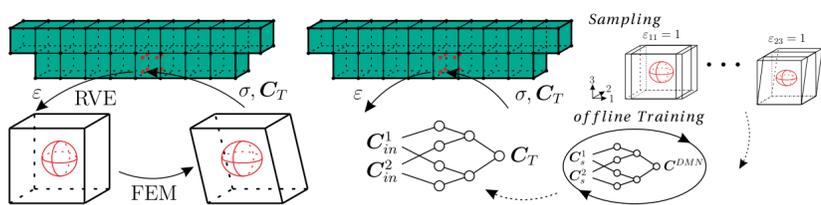


Abbildung 1: Konzept FE^2 (links) im Vergleich zum DMN (rechts)

Das DMN bietet zudem die Möglichkeit einer materiellen Extrapolation ohne eine erneute Kalibrierung der Parameter, begründet durch den physikalisch motivierten Aufbau. Nach dem Training kann das DMN, trainiert auf eine feste RVE-Geometrie, für beliebige, nichtlineare Materialien der Einzelphasen verwendet werden.

2. Theorie eines Deep Material Network

Das DMN ist eine netzartige Struktur, bestehend aus Knoten und Verbindungen. Die Knoten können als unabhängige Materialmatrizen C^1, C^2 und die Verbindungen als analytische Homogenisierungsregel F mit einer anschließenden Rotation G beschrieben werden. Durch das DMN werden die Materialmatrizen der Einzelphasen zu einer homogenisierten Materialmatrix C^{DMN} vereint.

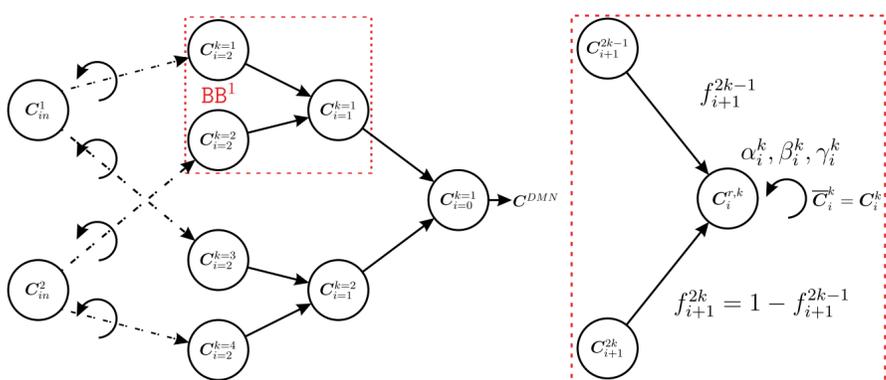


Abbildung 2: DMN (links, $N = 2$) und Building Block (BB) (rechts)

Die Parameter des DMN können durch die Vorschriften F und G als das Volumenverhältnis der Einzelphasen f und die drei Rotationswinkel α, β, γ der einzelnen BBs identifiziert und mit Methoden des maschinellen Lernens durch die Minimierung des Fehlers

$$C_0(z, \alpha, \beta, \gamma) = \frac{1}{2N_s} \sum_s \frac{\|C_s^{DNS} - H(C^1, C^2, f_1, \alpha, \beta, \gamma)\|^2}{\|C_s^{DNS}\|^2}$$

kalibriert werden. Um komplexe Mikrostrukturen zu approximieren wird ein Multi-Layer DMN, hierarchisch aus einzelnen BBs zu einer Netzstruktur mit einer Netztiefe N aufgebaut.

3. Das DMN als Materialmodell in der FEM

Nach erfolgreichem Trainingsprozess kann das DMN im Rahmen der FEM als Materialmodell eingesetzt werden. Die Knoten der Eingangsschicht des DMN können als unabhängige Mikro-Materialknoten und der Ausgabe-Knoten als Makro-Materialknoten interpretiert werden. Durch ein Iterationsverfahren auf Materialpunkt-Ebene können beliebige nichtlineare Materialgesetze

$$\begin{aligned} C_N^j &= C_N^j \left[\epsilon_N^j(\lambda_m \mathbf{P}), \Delta \epsilon_N^j, \sigma_N^j(\lambda_{m-1} \mathbf{P}), \mathbf{h} \right] \\ \sigma_N^j(\lambda_m \mathbf{P}) &= \sigma_N^j \left[\epsilon_N^j(\lambda_m \mathbf{P}), \Delta \epsilon_N^j, \sigma_N^j(\lambda_{m-1} \mathbf{P}), \mathbf{h} \right], \end{aligned}$$

abhängig von den materialspezifischen History-Variablen \mathbf{h} , in den Knoten auf Mikro-Ebene aufgerufen und die entsprechenden Verzerrungskremente $\Delta \epsilon_N^j$ ausiteriert werden. Durch den Trainingsprozess wird ausschließlich die geometrische Beschaffenheit des RVE unabhängig der Wahl der Materialien trainiert. Somit ist eine Wahl beliebiger Materialgesetze möglich.

4. Numerisches Beispiel

Am Beispiel einer Cook-Membran mit einem mikrostrukturellen Aufbau, bestehend aus einer elasto-plastischen Matrix mit einem kugelförmigen elastischen Einschluss, wird der Einsatz des DMN für die Netztiefen $N = 4, 5$ und 6 demonstriert.

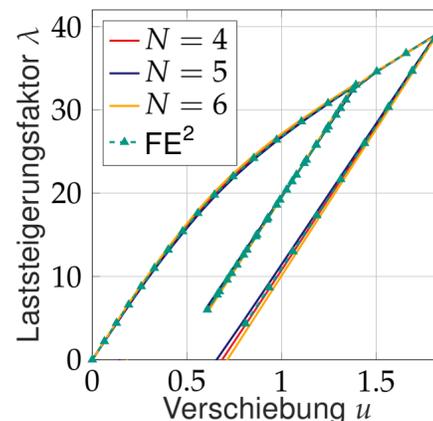


Abbildung 3: Spitzenverschiebung u der Ecke

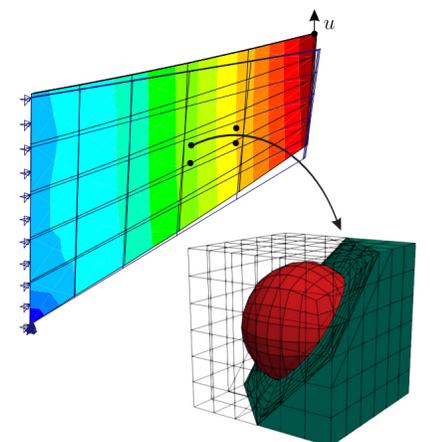


Abbildung 4: Verschiebungsfigur nach Entlastung

Das DMN liefert bei 5% der Rechenzeit der klassischen Mehrskalen-Simulation mit FE^2 sehr gute Ergebnisse mit einem Unterschied der maximalen Verformung von 0,01%.