

Zastosowanie technik sztucznej inteligencji w analizie odwrotnej

Ł. Sztangret, D. Szeliga, J. Kusiak, M. Pietrzyk

Katedra Informatyki Stosowanej i Modelowania
Akademia Górniczo-Hutnicza, Kraków

Motywacja


Dokładność symulacji MES procesów przetwórstwa materiałów zależy w dużym stopniu od prawidłowości opisu własności reologicznych.

Próby plastometryczne są powszechnie stosowane do wyznaczenia tych własności.

Każda z prób plastometrycznych jest obarczona zakłóceniami, związanymi z wpływem tarcia, ciepła generowanego przez odkształcenie plastyczne itp.

Rozwiązanie odwrotne pozwala wyeliminować lub przynajmniej ograniczyć wpływ tych zakłóceń.

Rozwiązanie odwrotne wymaga bardzo długich czasów obliczeń



Plan prezentacji

1. Klasyczne rozwiązanie odwrotne
2. Metamodel oparty o sztuczne sieci neuronowe
3. Zastosowane metody optymalizacji
4. Weryfikacja otrzymanych parametrów modelu reologicznego
 1. Wykonane doświadczenie
 2. Porównanie wyników doświadczalnych z otrzymanymi
5. Podsumowanie



1. Klasyczne rozwiązanie odwrotne

Analiza Inverse – przykładowy wynik

Różne próby plastometryczne dla stali
Ściskanie próbek płaskich i osiowosymetrycznych

klasyczne (siła/powierzchnia)

analiza inverse



Podstawy rozwiązywania odwrotnego dla modelu reologicznego

Dowolny proces przetwórstwa materiałów jest opisany przez układ równań:

$$\mathbf{d} = F(\mathbf{x}, \mathbf{p}), \quad F : R^l \rightarrow R^k$$

gdzie:

$\mathbf{d} = \{d_1, \dots, d_k\}$ - Wektor parametrów wyjściowych


$\mathbf{p} = \{p_1, \dots, p_l\}$ - Wektor zmiennych zewnętrznych opisujących warunki procesu

$\mathbf{x} = \{x_1, \dots, x_r\}$ - Wektor parametrów w modelu reologicznym

$\mathbf{d}$ – siły, kształt próbki po odkształceniu, . . .

$\mathbf{p}$ – temperatura, prędkość odkształcenia, . . .

Analiza Inverse



Parametry modelu reologicznego
wyznaczone z warunku minimum
funkcji celu:

$$\Phi(\mathbf{x}) = \sum_{i=1}^n \beta_i [\mathbf{d}_i^c(\mathbf{x}, \mathbf{p}) - \mathbf{d}_i^m]^2$$

Przykładowe funkcje celu

Dla identyfikacji parametrów materiałowych

$$\phi = \sqrt{\frac{1}{N_t} \sum_{i=1}^{N_t} \left[\frac{1}{N_s} \sum_{j=1}^{N_s} \left(\frac{F_{ij}^m - F_{ij}^c}{F_{ij}^m} \right)^2 \right]}$$

N_t – liczba prób, N_s – liczba pomiarów siły w jednej próbie, F_{ij}^m , F_{ij}^c – zmierzona i obliczona siła

Inne stosowane funkcje celu:

$$\Phi = \sqrt{\frac{1}{N_t N_{pr}} \sum_{i=1}^{N_t} \sum_{j=1}^{N_{pr}} \left[\left(\frac{R_{cij}^{in} - R_{mij}^{in}}{R_{mij}^{in}} \right)^2 + \left(\frac{R_{cij}^{out} - R_{mij}^{out}}{R_{mij}^{out}} \right)^2 \right]}$$

$$\Phi = \left\{ \frac{1}{N_t} \left[\frac{1}{N_{pr}} \sum_{i=1}^{N_t} \sum_{j=1}^{N_{pr}} \left[\left(\frac{R_{cij}^{in} - R_{mij}^{in}}{R_{mij}^{in}} \right)^2 + \left(\frac{R_{cij}^{out} - R_{mij}^{out}}{R_{mij}^{out}} \right)^2 \right] + \frac{1}{N_{pl}} \sum_{i=1}^{N_t} \sum_{j=1}^{N_{pl}} \left(\frac{F_{cij} - F_{mij}}{F_{mij}} \right)^2 \right] \right\}^{1/2}$$

Model rozwiązania wprost

Różniczkowe równanie równowagi naprężeń

Mocna forma

$$\frac{\partial \sigma_{ij}}{\partial x_j} = 0$$


Słaba forma

$$\int_{\Omega} \frac{\partial \sigma_{ij}}{\partial x_j} \delta v_i d\Omega = 0$$

δv_i – wariacja v_i

Całkowanie przez części

$$\int_{\Omega} \sigma_{ij} \frac{\partial (\delta v_i)}{\partial x_j} d\Omega - \int_{\Omega} \frac{\partial}{\partial x_j} (\sigma_{ij} \delta v_i) d\Omega = 0$$



Teoria o dywergencji
i warunek nieściśliwości

$$J = \int_{\Omega} \sigma_i \dot{\epsilon}_i d\Omega + \lambda \int_{\Omega} \dot{\epsilon}_v d\Omega - \int_{\Gamma} \hat{\mathbf{f}}^T \hat{\mathbf{v}} d\Gamma$$

Dyskretyzacja

$$\hat{\mathbf{v}} = \mathbf{n}^T \mathbf{v}$$

minimum funkcjonału

$$\frac{\partial J}{\partial \mathbf{v}^T} = 0$$

$$\sqrt{\frac{2}{3}} \sigma_i \int_{\Omega} \frac{\mathbf{K} \mathbf{v}}{\sqrt{\mathbf{v}^T \mathbf{K} \mathbf{v}}} d\Omega + \lambda \int_{\Omega} \mathbf{B}^T \mathbf{c} d\Omega - \int_{\Gamma} \mathbf{n}^T \mathbf{f} d\Gamma = 0$$

Układ równań względem $\mathbf{v}$ i λ

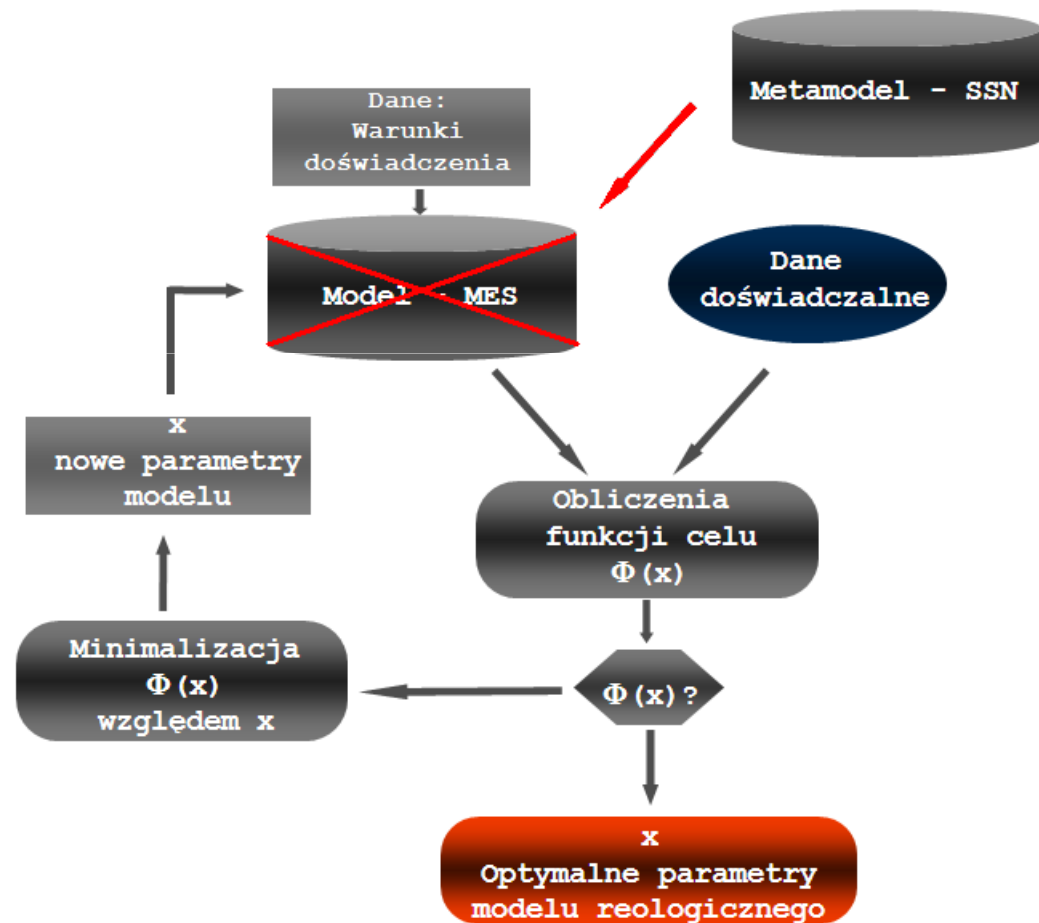
$$\nabla(k \nabla T) + Q = \rho c_p \frac{\partial T}{\partial t}$$

$$\mathbf{K} \mathbf{T} + \mathbf{M} \dot{\mathbf{T}} = \mathbf{f}$$

Układ równań
względem $\mathbf{T}$

Cel

Sprawdzenie, czy
model MES można
zastąpić
metamodelem
zbudowanym w
oparciu o SSN



Model reologiczny

Hansel & Spittel:

$$\sigma_p = x_1 \varepsilon^{x_2} \exp(-x_3 \varepsilon) \dot{\varepsilon}^{x_4} \exp(-x_5 T)$$

ε - odkształcenie

$\dot{\varepsilon}$ - prędkość odkształcenia


T - temperatura

$$\mathbf{x} = \{x_1, x_2, x_3, x_4, x_5\}$$

2. Metamodel oparty o sztuczne sieci neuronowe

Metamodel oparty o Sztuczne Sieci Neuronowe

$$\phi = \sqrt{\frac{1}{Nt} \sum_{i=1}^{Nt} \left[\frac{1}{Ns} \sum_{j=1}^{Ns} \left(\frac{F_{ij}^m - F_{ij}^c}{F_{ij}^m} \right)^2 \right]}$$



W skład metamodelu
wchodzi 10 sieci MLP

Uczenie sieci

Dane otrzymane z symulacji MES

- Dane uczące 32442 rekordów
- Dane testowe 10000 rekordów

Filtrowanie


- Min-Max

Wyniki uczenia sieci


Siła	Struktura	Błąd [%]
F ₁	8-5-3-1	0,0328
F ₂	8-5-3-1	0,0665
F ₃	8-15-5-1	0,0815
F ₄	8-5-3-1	0,1087
F ₅	8-15-5-1	0,2086
F ₆	8-5-3-1	0,2403
F ₇	8-5-3-1	0,1762
F ₈	8-15-5-1	0,0857
F ₉	8-15-5-1	0,1806
F ₁₀	8-15-5-1	0,2017

$$\Phi_i = \frac{\sqrt{\frac{1}{n} \sum_{j=1}^n (F_{i,j}^O - F_{i,j}^{SSN})^2}}{\max_j \{F_{i,j}^O\} - \min_j \{F_{i,j}^O\}} \cdot 100[\%]$$

Analiza Inverse



Analiza Inverse



Parametry modelu reologicznego
wyznaczane z warunku minimum
funkcji celu:

$$\phi = \sqrt{\frac{1}{Nt} \sum_{i=1}^{Nt} \left[\frac{1}{Ns} \sum_{j=1}^{Ns} \left(\frac{F_{ij}^m - F_{ij}^c}{F_{ij}^m} \right)^2 \right]}$$

3. Zastosowane metody optymalizacji

Metody niedeterministyczne

1. Algorytmy genetyczne (GA).
2. Algorytmy ewolucyjne (EA).
 1. strategia (1+1),
 2. strategia ($\mu+\lambda$),
 3. strategia (μ,λ).
3. Metoda roju cząstek (PSO).
4. Metoda roju cząstek wspomagana procedurą analizy wrażliwości (PSO+SA)
5. Metoda symulowanego wyżarzania (SA).
6. Algorytmy mrówkowe (ACO).
7. Algorytmy immunologiczne (AIS).

Algorytm roju cząstek (PSO)

Kroki algorytmu:

1. Nadanie cząstkom początkowych wartości położenia i prędkości.
2. Obliczenie wartości przystosowania każdej cząstki w roju.
3. Zapamiętanie położenia najlepszej cząstki w roju oraz zapamiętanie najlepszego położenia każdej cząstki.
4. Wyznaczenie nowej prędkości każdej cząstki

$$v_{k+1}^i = wv_k^i + c_1r_1(p^i - x_k^i) + c_2r_2(p^g - x_k^i)$$

5. Wyznaczenie nowego położenie każdej cząstki

$$x_{k+1}^i = x_k^i + v_{k+1}^i$$

Algorytm roju cząstek + analiza wrażliwości (PSO+SA)

Kroki algorytmu:

1. Nadanie cząstkom początkowych wartości położenia i prędkości.
2. Obliczenie wartości przystosowania każdej cząstki w roju.
3. Zapamiętanie położenia najlepszej cząstki w roju oraz zapamiętanie najlepszego położenia każdej cząstki.
4. Wyznaczenie nowej prędkości każdej cząstki

$$v_{k+1}^i = w' v_k^i + c'_1 r_1 (p^i - x_k^i) + c'_2 r_2 (p^g - x_k^i) + c'_3 r_3 k^i$$


5. Wyznaczenie nowego położenie każdej cząstki

$$x_{k+1}^i = x_k^i + v_{k+1}^i$$

Analiza wrażliwości (SA)

Krok 1 – sąsiedztwo


$$S^i = \{j \in I : \|x^i - x^j\| < d\}$$



Analiza wrażliwości (SA)


Krok 1 – sąsiedztwo

$$S^i = \{j \in I : \|x^i - x^j\| < d\}$$




Analiza wrażliwości (SA)

Krok 2 – wektor korekcji $k^i = \sum_{j \in S^i} \frac{-(f(x^j) - f(x^i))}{\|x^j - x^i\|} \cdot (x^j - x^i)$




Analiza wrażliwości (SA)

Krok 2 – wektor korekcji $k^i = \sum_{j \in S^i} \frac{-(f(x^j) - f(x^i))}{\|x^j - x^i\|} \cdot (x^j - x^i)$




Analiza wrażliwości (SA)

Krok 3 – współczynnik niepewności $\alpha^i = \frac{\sum_{j \in S^i} \|x^j - x^i\|}{|S^i| \cdot l}$



Analiza wrażliwości (SA)

Krok 3 – współczynnik niepewności $\alpha^i = \frac{\sum_{j \in S^i} \|x^j - x^i\|}{|S^i| \cdot l}$



Algorytm roju cząstek + analiza wrażliwości

Uwzględnienie wektora korekcji jest uzależnione od wartości współczynnika niepewności.

Dla $\alpha^i > \delta$

$$w' = w$$

$$c'_1 = c_1$$

$$c'_2 = c_2$$

$$c'_3 = 0$$

Dla $\alpha^i \leq \delta$

$$w' = w \cdot \beta$$

$$c'_1 = c_1 \cdot \beta$$


$$c'_2 = c_2 \cdot \beta$$

$$c'_3 = c_3 \cdot (1 - \beta)$$

$$\beta = \sqrt{\frac{\alpha^i}{\delta}}$$

Funkcja testowa Rastrigina

$$f(x_1, x_2) = x_1^2 + x_2^2 - \cos(18x_1) - \cos(18x_2) + 2$$




$$\varepsilon = 10^{-5}$$

$$N = 2000$$

Funkcja testowa Rosenbrocka





$$f(x_1, x_2) = 100 \cdot (x_2 - x_1^2)^2 + (1 - x_1)^2$$



$$\varepsilon = 10^{-5}$$

$$N = 2000$$

Wyniki optymalizacji



4. Weryfikacja otrzymanych parametrów modelu reologicznego

Doświadczenie

Próby ściskania próbek
osiowosymetrycznych
wykonano na symulatorze
Gleeble 3800 w IMŻ Gliwice



Typowe wyniki pomiarów:

Materiał: stal austenityczna

Wymiary próbki $\phi 12 \times 10$ mm

Warunki prób:


temperatury 900, 1000 i 1100°C

prędkości odkształcenia 0.1, 1 i 10 s⁻¹


stopień odkształcenia 1

Rejestrowano:

siłę w funkcji przemieszczenia



Wyniki optymalizacji



$\varepsilon = 10\%$

$N = 3000$

$$\phi = \sqrt{\frac{1}{Nt} \sum_{i=1}^{Nt} \left[\frac{1}{Ns} \sum_{j=1}^{Ns} \left(\frac{F_{ij}^m - F_{ij}^c}{F_{ij}^m} \right)^2 \right]} \cdot 100[\%]$$

Analiza Inverse - wyniki

Optymalne współczynniki w modelu reologicznym:

$$x_1 = 17187.3$$

$$x_2 = 0.3$$

$$x_3 = 0.47$$




$$x_4 = 0.098$$

$$x_5 = 4.05$$

$$\Phi = 9.55\%$$

$$\sigma_p = 17187.3 \varepsilon^{0.3} \exp(-0.47 \varepsilon) \dot{\varepsilon}^{0.098} \exp(-4.05 T)$$

Weryfikacja rozwiązania inverse opartego o metamodel



Symbole pełne – pomiar na Gleeble
Symbole otwarte – symulacja MES ze współczynnikami modelu krzywej umocnienia uzyskanymi z rozwiązania inverse w oparciu o metamodel

Podsumowanie


Metamodel pozwala na symulację prób plastometrycznych z dobrą dokładnością.

Zastosowanie metamodelu w rozwiązaniu odwrotnym pozwala na wielokrotne przyspieszenie obliczeń i, w konsekwencji, na wykorzystanie zaawansowanych technik optymalizacji.

Kierunki dalszych badań

Zastosowanie rozwiązania odwrotnego do identyfikacji bardziej skomplikowanych modeli reologicznych – model Sellarsa lub model zmiennej wewnętrznej.

Opracowanie metamodelu dla innych prób doświadczalnych, np. do próby dylatometrycznej.



DZIĘKUJĘ ZA UWAGĘ

Łukasz Sztangret

szt@agh.edu.pl

Katedra Informatyki Stosowanej i Modelowania
Akademia Górniczo-Hutnicza, Kraków

NeuroMet 2010