

МОДЕЛЬ ПЛАСТИЧНОГО СТАНУ МАТЕРІАЛУ ДЛЯ ШИРОКОГО ДІАПАЗОНУ ТЕМПЕРАТУР ТА ШВИДКОСТЕЙ ДЕФОРМАЦІЙ НА БАЗІ НЕЙРОННОЇ МЕРЕЖІ

В.Л. Хавін, професор, к.т.н., О.О. Огородник, аспірант, НТУ «ХПІ»

Анотація. Розглянуто підхід до розробки моделі матеріалу на базі штучної нейронної мережі, що описує пластичну течію. Особливістю моделі є можливість моделювання пластичного стану матеріалу у широкому діапазоні пластичних деформацій, швидкостей деформацій та температур. На прикладі сталі 45 проведено порівняльний аналіз ефективності навчання для різноманітних варіантів підготовки тренувальних даних.

Ключові слова: модель матеріалу, нейронні мережі, пластичний стан матеріалу, високошвидкісне деформування.

МОДЕЛЬ ПЛАСТИЧЕСКОГО СОСТОЯНИЯ МАТЕРИАЛА ДЛЯ ШИРОКОГО ДИАПАЗОНА ТЕМПЕРАТУР И СКОРОСТЕЙ ДЕФОРМАЦИЙ НА ОСНОВЕ НЕЙРОННОЙ СЕТИ

В.Л. Хавин, профессор, к.т.н., А.О. Огородник, аспирант, НТУ «ХПИ»

Аннотация. Рассмотрен подход к разработке модели материала на базе нейронной сети, описывающей пластическое течение. Особенностью модели является возможность моделирования пластического состояния материала в широком диапазоне пластических деформации, скоростей деформаций и температур. На примере стали 45 проведен сравнительный анализ эффективности обучения для различных вариантов подготовки обучающих данных.

Ключевые слова: модель материала, нейронные сети, пластическое состояние материала, высокоскоростное деформирование.

THE FLOW-STRESS MATERIAL MODEL FOR WIDE RANG OF STRAIN RATE AND TEMPERATUR BASED ON AN ARTIFICIAL NEURAL NETWORK

V.L. Khavin, professor, cand. eng. sc.,
O.O. Ogorodnyk, post graduate student, NTU «KhPI»

Abstract. An approach to development of a material model based on artificial neural network describing plastic flow was considered. Model's feature is possibility to model flow behavior of material in wide range of strain, strain rate and temperature. On an example for AISI 45 the benchmark analysis of training for various variants of the learning data preparation was carried out.

Keywords: material model, neural networks, flow-stress state of the material, high-strain deformation.

Вступ

При моделюванні процесів механічної обробки, пов'язаних з пластичним деформуванням матеріалу, важливу роль відіграє корек-

тне описання властивостей матеріалу у широкому діапазоні пластичних деформацій, швидкостей деформацій та температур. У подібних процесах поведінка матеріалу задається визначальним рівнянням. Визначальне

рівняння (матеріальне рівняння, constitutive equation) описує поведінку матеріалу через залежність напруження пластичної течії $\bar{\sigma}_\gamma$ від еквівалентних пластичних деформацій $\bar{\varepsilon}_p$, швидкостей еквівалентних пластичних деформацій $\dot{\bar{\varepsilon}}_p$ і температур T .

$$\sigma_\gamma = \sigma_\gamma(\bar{\varepsilon}_p, \dot{\bar{\varepsilon}}_p, T). \quad (1)$$

Аналіз публікацій

Існує безліч рівнянь, що описують пластичних станів матеріалу. Найбільш розповсюдженими моделями, визначальними рівняннями (1), при моделюванні процесів механічної обробки є напівемпіричні залежності. Тим не менш кореляція з експериментальними даними, наприклад із зусиллями при обробці різанням ($\varepsilon = 0,002-5$; $\dot{\varepsilon} = 0,001-100000 \text{ c}^{-1}$; $T = 20-1000 \text{ }^\circ\text{C}$), все ще залишається не на достатньому рівні. Через це у останні роки виник новий напрям у сфері розробок матеріалу, пов'язаного з застосуванням нейронних мереж (НМ, Artificial neural network, ANN), що зарекомендували себе як ефективний метод апроксимації складних нелінійних залежностей [1, 2]. Так, у ряді публікацій [3,4] останнього десятиріччя для опису властивостей металів та їх сплавів успішно застосовуються НМ. У роботах [5, 6] розглядаються шляхи удосконалення нейромережових моделей (НМ-моделі) матеріалу шляхом удосконалення способу підготовки даних, а також варіювання внутрішньої структури нейронних мереж.

Ціль роботи та постановка задачі

У статті розглянуті особливості розробки визначального рівняння матеріалу (для сталі 4 для сталі 45) з використанням НМ для широкого діапазону швидкостей деформацій та температур, властивих процесу обробки різанням.

У роботі необхідно було вирішити наступні задачі:

- підготувати набір експериментальних даних по сталі 45 для тренування і тестування НМ;
- підібрати оптимальну і ефективну архітектуру НМ, вибрати найбільш придатний метод навчання мережі;

- вибрати кращий варіант підготовки вибірки для навчання НМ, що забезпечую кращу точність апроксимації.

Структура НМ-моделі та її навчання

На рис. 1 показано загальну схему обраної НМ-моделі. При процесі високошвидкісного пластичного деформування (різання) напруження пластичної плинності матеріалу залежить в основному від трьох параметрів деформацій, швидкості деформацій та температури. У використовуваній НМ-моделі вхідний шар відповідає цим трьом параметрам, а вихідний шар представлений одним параметром – напруженням пластичної течії. Мережа, що застосовується у роботі, є перцептронном з послідовними зв'язками з одним прихованим шаром, що є оптимальним варіантом для апроксимації неперервних функцій [3, 4]. Прихований шар містить 5 вузлів.




Рис. 1. Схема нейронної мережі на базі перцептрону з трьома шарами

Експериментальні дані по сталі 45 (AISI 1045) для навчання НМ задавалися у табличній формі з бази даних по матеріалам програмного комплексу Deform v.10. Дані представлені для наступних деформацій [0.002, 0.05, 0.1, 0.4, 0.7, 1, 2, 5], швидкостей деформацій [0.001, 1, 100, 1000, 10000, 100000] c^{-1} , температур [20..1000] $^\circ\text{C}$ з кроком у 100 $^\circ\text{C}$.

Практика показала, що для досягнення кращих результатів роботи мережі дання перед навчанням необхідно нормалізувати. Тобто усі експериментальні дані, що використовуються для навчання нейронної мережі необхідно привести до діапазону від 0 до 1. Для навчання НМ були використані наступні варіанти вхідного вектору: $(\varepsilon, \dot{\varepsilon}, T)$,

$(\varepsilon, \ln(\dot{\varepsilon}), T), (\ln(\varepsilon), \ln(\dot{\varepsilon}), T), (\ln(\varepsilon), \ln(\dot{\varepsilon}), T^{-1})$.

При навчанні НМ критерієм зупинки процесу навчання може слугувати як оцінка збіжності експериментальних даних, так і кількість навчальних ітерацій. У даній роботі було використано критерій по кількості ітерацій. Дослідним шляхом визначено, що до позначки 10000 ітерацій похибка зменшується. Після чого значних змін у якості процесу навчання не відбувається. У процесі підготовки даних було сформовано 594 набору даних. З яких 495 (83%) використано для навчання, а 99 (17%) для перевірки працездатності НМ. Належить відмітити, що на відміну від відомих робіт, де навчальний та перевірочний набори вибирались із масиву даних випадковим чином, у даній роботі в якості перевірочного набору було вибрано ціле сімейство кривих деформування для $\dot{\varepsilon} = 1000 \text{ c}^{-1}$, що представляє більш «жорсткі» вимоги до якості навчання мережі.

Перевірка працездатності моделі

Ефективність роботи мережі визначалась за допомогою середньої відносної похибки (average absolute relative error, AARE) та коефіцієнту кореляції (R):

$$AARE(\%) = \frac{1}{N} \sum_{i=1}^N \left| \frac{E_i - P_i}{E_i} \right| \times 100,$$

$$R = \frac{\sum_{i=1}^N (E_i - \bar{E})(P_i - \bar{P})}{\sqrt{\sum_{i=1}^N (E_i - \bar{E})^2 \sum_{i=1}^N (P_i - \bar{P})^2}},$$

де E – дані отримані з експериментального набору, P – дані отримані за допомогою нейронної мережі, \bar{E} і \bar{P} – середні значення E і P відповідно, N – загальна кількість даних використаних при розрахунках.

Табл. 1 показує ефективність роботи моделі при різних варіантах підготовки даних для навчального та тестового наборів. З таблиці видно, що після обробки даних по швидкості деформацій логарифмічною функцією результат значно покращується. Це добре видно для тестового набору.

Таблиця 1 Порівняння похибок для різних варіантів навчального та перевірочного наборів

№	Варіант підготовки даних	Навчальний набір		Перевірочний набір	
		ARRE, %	R	ARRE, %	R
1	$\varepsilon, \dot{\varepsilon}, T$	9,604	0,992	52,407	0,987
2	$\varepsilon, \ln(\dot{\varepsilon}), T$	8,132	0,995	10,290	0,987
3	$\ln(\varepsilon), \ln(\dot{\varepsilon}), T$	10,18	0,996	21,343	0,996
4	$\ln(\varepsilon), \ln(\dot{\varepsilon}), T^{-1}$	21,7	0,962	29,568	0,954

Збіжність погіршується при застосуванні логарифмічної функції до ряду значень деформації. Це пояснюється тим, що у випадку зі швидкістю деформацій логарифмічна функція створила інтервали між точками даних майже однокові, а для ряду даних по деформаціям таких явних змін не відбулось. Отримані результати тестування показали, що для покращення ефективності моделі, навчальні дані необхідно нормалізувати та приводити до упорядкованого виду, а кращі результати навчання дає тренувальний набір №2.

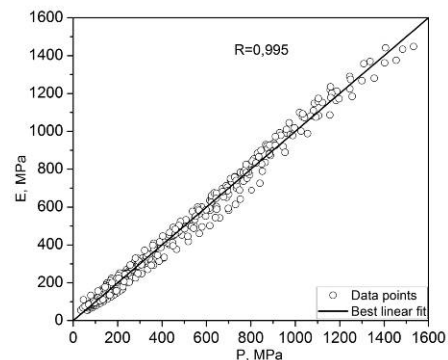


Рис. 2. Кореляція між експ. даними (E) та даними НМ (P). (набір даних №2)




Рис. 3. Залежність відносної похибки від температури T при деформації $\varepsilon = 0,4$ для різних швидкостей деформацій ε' (набір даних №2)




Рис. 4. Збіжність експериментальних даних з отриманими за допомогою НМ на прикладі сімейства кривих плинності сталі 45 для швидкості деформацій 1 c^{-1} (набір даних №2)

Як видно з рис. 3, 4 найменша точність апроксимації спостерігається на межах діапазонів усіх трьох параметрів, що є нормальним для штучної НМ. Отримані результати показали добру якість навчання – середня відносна похибка для навчального (8,1%) та тестового (10,3%) набору даних.

Висновки

У роботі розглянуто особливості розробки НМ-моделі пластичного стану матеріалу для широкого діапазону швидкостей та температур відносно до сталі 45. При навчанні нейронної мережі було використано різні варіанти підготовки даних. Отримано кращий варіант структури вхідних даних, який забезпечив високу ефективність апроксимації сімейства кривих деформування як для навчальної вибірки, так і для «жорсткої» перевірконої вибірки. Це показує можливість успішного застосування даної моделі у поєднанні з МСЕ при моделюванні процесів обробки металу різанням.

Література

1. Haj-Ali R.M., Pecknold D.A., Ghaboussi J., Voyiadjis G.Z. Simulated Micromechanical Models using Artificial Neural Networks // ASCE J. Eng. Mechanics, 2001 – Vol. 127, No. 7 – с. 730-738.
2. Hashash Y.M.A., Jung S., Ghaboussi J., Numerical implementation of a neural network based material // International journal for numerical methods in engineering, 2004 – 59 – с. 989–1005.
3. Sumantra Mandal, Sivaprasad P.V., Venugopal S., Murthy K.P.N. Constitutive flow behaviour of austenitic stainless steels under hot deformation: artificial neural network modelling to understand, evaluate and predict // Modelling Simul. Mater. Sci. Eng. 2006 – 14 – с. 1053-1070.
4. D'Addona D., Teti R., Intelligent Material Modelling for Mild Steel Hot Working, Vimation Journal, Special Issue on Interactive Systems in Healthcare, 2010 – ISSN 1866-4245 – с. 79-83.
5. Wang B., Kong L.X., Hodgson P.D., Collinson D.C., Improvement of the Prediction Accuracy and Efficiency of Hot Strength of Austenitic Steels with Optimised ANN Training Schemes // Metals and materials international, 1998 –Volume 4, Number 4 – с. 823-826.
6. Sha, W., Edwards, K. L., The use of artificial neural networks in materials science based research // Materials and Design, 2007 – Vol.28, No.6 – с. 1747-1752.

Рецензент: В.М. Конкін, професор, к.т.н., НТУ «ХП».

Стаття поступила в редакцію 28 жовтня 2011 р.