

В.Л.ХАВИН, канд. техн. наук, профессор, зав. каф., НТУ «ХПИ»;
О.А.ОГОРОДНИК, аспирант, НТУ «ХПИ»

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

Розглянуто підхід до розробки 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 ($0,001\dots10^5\text{ s}^{-1}$) та температур ($20\dots1000^\circ\text{C}$). Для реалізації моделі була використана нейронна мережа на основі персептрона з одним прихованим шаром. На прикладі експериментальної сім'ї кривих деформування стали 45 проведено порівняльний аналіз ефективності навчання для різноманітних варіантів підготовки тренувальних даних.

An approach to model development of a material 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 ($0,001\dots10^5\text{ s}^{-1}$) and temperature ($20\dots1000^\circ\text{C}$). For model implementation the neural network based on the perceptron with one hidden layer has been used. On an example of the experimental family of strain curves for AISI 45 the benchmark analysis of training for various variants of the learning data preparation was carried out.

Рассмотрен поход к разработке модели материала на базе искусственной нейронной сети, описывающей пластическое течение. Особенностью модели является возможность моделирования пластического состояния материала в широком диапазоне пластических деформаций, скоростей деформаций ($0,001\dots10^5\text{ s}^{-1}$) и температур ($20\dots1000^\circ\text{C}$). Для реализации модели была использована нейронная сеть на основе перцептрана с одним скрытым слоем. На примере экспериментального семейства кривых деформирования для стали 45 проведен сравнительный анализ эффективности обучения для различных вариантов подготовки обучающих данных.

1 Введение. При моделировании процессов механообработки, связанных с пластическим деформированием материала, важную роль играет корректное описание свойств материала в широком диапазоне пластических деформаций, скоростей деформаций и температур. В подобных процессах поведение материала задается определяющим уравнением. Определяющее уравнение (материальное уравнение, constitutive equation) описывает поведение материала через зависимость напряжений пластического течения (текущего предела текучести) $\bar{\sigma}_y$ от эквивалентных пластических деформаций $\bar{\varepsilon}_p$, скоростей эквивалентных пластических деформаций $\dot{\bar{\varepsilon}}_p$ и температур T .

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

Обычно определяющее уравнение создается на основе кривых деформирования, полученных путем испытаний на одноосное растяжение (сжатие) или сдвиг. Существует множество уравнений, описывающих пластическое состояние материала. Самые простые модели способны показать общую картину поведения материала, но не способны отобразить все многообразие по-

ведения материала, включающее существенную неоднородность и в широком диапазоне скоростей деформаций и температур [2].

2 Анализ литературы и постановка задачи. Наиболее распространеными моделями, определяющими уравнениями, при моделировании процессов механообработки являются полуэмпирические зависимости. Среди них можно отметить уравнение Джонсона-Кука (Johnson-Cook) [10], уравнение Зерилли-Армстронга (Zerilli-Armstrong) [11] и уравнение Оксли (Oxley) [12]. Благодаря своей простоте (до 5 констант) и способности качественно описать кривые деформирования в широком диапазоне температур и скоростей деформации эти уравнения получили распространение в практических расчетах [3]. Тем не менее корреляция с экспериментальными данными, например с усилиями при обработке резанием ($\epsilon = 0,002-5$; $\dot{\epsilon} = 0,001-100000 \text{ с}^{-1}$; $T = 20-1000^\circ\text{C}$), все еще остается не на достаточном уровне. Поэтому в последние годы возникало новое направление в области разработок моделей материала, связанное с применением искусственных нейронных сетей (НС, Artificial neural network, ANN), которые зарекомендовали себя как эффективный метод аппроксимации сложных нелинейных зависимостей [1, 2].

Так, в ряде публикаций [4-6] последнего десятилетия для описания свойств металлов и сплавов успешно применяются НС. В работах [7, 8] рассматриваются пути совершенствования нейросетевых моделей материала путем совершенствования способа подготовки данных, а так же варьированием внутренней структуры нейронных сетей.

В настоящей работе предложена нейросетевая модель (НС-модель) определяющая состояние материала, способная адекватно описать пластическое деформирование в широком диапазоне скоростей деформаций и температур свойственных процессу обработки резанием. Показана работоспособность модели на примере стали 45, и получены предварительные результаты.

3 Цель работы. В статье рассмотрены особенности разработки определяющего уравнения материала (для Стали 45) с применением НС для широкого диапазона скоростей деформаций и температур.

В работе необходимо было решить следующие задачи:

1. Подготовить набор экспериментальных данных по стали 45 для тренировки и тестирования НС в широком диапазоне деформаций, скоростей деформаций и температур ($\epsilon = 0,002-5$; $\dot{\epsilon} = 0,001-100000 \text{ с}^{-1}$; $T = 20-1000^\circ\text{C}$).

2. Подобрать эффективную НС с оптимальной архитектурой. Выбрать наиболее подходящий метод обучения сети.

3. Провести обучение НС с помощью тренировочного набора данных, варьируя структуру входных данных. На основе этого выбрать лучший вариант подготовки выборки для обучения НС, обеспечивающий лучшую точность аппроксимации.

4 Особенности НС-модели и структура данных. Как уже отмечалось известные полуэмпирические математические модели материалов являются

ограниченными и могут давать значительные ошибки при изменении диапазона параметров. Нейронные сети несколько лет назад были использованы как альтернатива эмпирическим и полуэмпирическим математическим моделям материала. Нейросетевой подход получил распространение в основной мере благодаря способности модели нейрона обучаться существенно-нелинейным взаимосвязям между входными и выходными параметрами системы. Неотъемлемыми свойствами НС в моделировании пластического поведения материала в сравнении с классическими подходами являются: способность к адаптации, распределенная память, способность к обобщению и строго параллельная структура. Благодаря этим свойствам НС не чувствительна к шумам (помехам) и обладает большой скоростью по обработке данных, что позволяет применять данный подход в сочетании с методом конечных элементов (МКЭ) [9].

5 Архитектура нейронной сети. На рис. 1 показана общая схема выбранной нейросетевой модели. При процессе высокоскоростного пластического деформирования (резания) напряжение пластического течения материала зависит в основном от трех независимых параметров: деформации, скорость деформаций и температура. В используемой нейросетевой модели входной слой соответствующий этим трем параметрам, а выходной слой представлен одним параметром – текущим пределом текучести. Сеть, применяемая в работе, является персептроном с последовательными связями с одним скрытым слоем, что является оптимальным вариантом для аппроксимации непрерывных функций [4, 5]. Скрытый слой содержит 5 узлов.

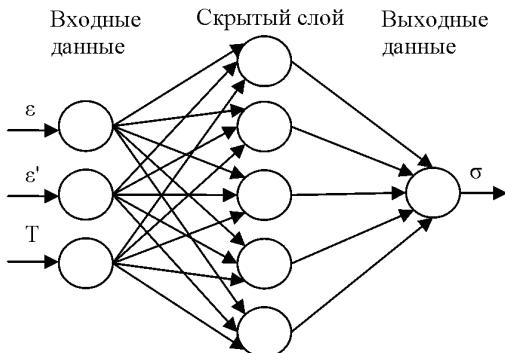


Рисунок 1 – Схема нейронной сети на базе персептрана с 3-мя слоями

6 Структура экспериментальных данных. Экспериментальные данные по стали 45 (AISI 1045) для обучения НС задавались в табличной форме из базы данных по материалам программного комплекса Deform v.10. Данные представлены для следующих деформаций [0,002; 0,05; 0,1; 0,4; 0,7; 1; 2; 5], скоростей деформаций [0,001; 1; 100; 1000; 10000; 100000] с^{-1} , температур

[20...1000] °C с шагом в 100 °C.

На рис. 2 показан пример семейства кривых деформирования построенных по используемым экспериментальным данным при скорости деформаций 100 s^{-1} для всего диапазона температур. По оси абсцисс – истинные деформации ε_p , по оси ординат – напряжения пластического течения σ_r .

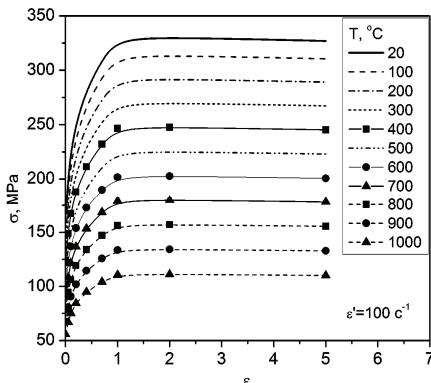


Рисунок 2 – Семейство кривых течения стали 45 при скорости деформаций 100 c^{-1}

7 Подготовка данных и обучение НС. Практика показала, что для достижения лучших результатов работы сети данные перед обучением необходимо нормализовать. Т.е. все экспериментальные данные, которые используются для обучения нейронной сети необходимо привести к диапазону от 0 до 1. Для нормализации был выбран простейший алгоритм, а именно деление всех значений на максимальное.

Для обучения НС были использованы следующие варианты входного вектора: $(\varepsilon, \dot{\varepsilon}, T)$, $(\varepsilon, \ln(\dot{\varepsilon}), T)$, $(\ln(\varepsilon), \ln(\dot{\varepsilon}), T)$, $(\ln(\varepsilon), \ln(\dot{\varepsilon}), T^{-1})$.

При обучении НС критерием завершения процесса обучения может служить как оценка сходимости экспериментальных данных с предсказанными, так и количеству обучающих итераций. В данной работе был использован критерий по количеству итераций. Опытным путем установлено, что до отметки 10000 итераций погрешность уменьшается. После чего значительных изменений в качестве процесса обучения не происходит.

В процессе подготовки данных было сформировано 594 набора данных. Из которых 495 (83 %) использовано для обучения, а 99 (17%) для проверки работоспособности НС. Следует отметить, что в отличии от известных работ [4], где обучающий и проверочный наборы выбирались из массива данных случайнным образом, в настоящей работе в качестве проверочного набора было выбрано все семейство кривых деформирования для $\dot{\varepsilon} = 1000 \text{ s}^{-1}$, что представляет более «жесткие» требования к качеству обучения сети.

8 Проверка работоспособности модели. Для оценки работоспособности модели использовались статистические критерии [4-6, 9]. Эффективность работы сети определялась и представлялась с помощью средней относительной погрешности (average absolute relative error, AARE) и коэффициента корреляции (R):

$$AARE(\%) = \frac{1}{N} \sum_{i=1}^N \left| \frac{E_i - P_i}{E_i} \right| \times 100; \quad R = \frac{\sum_{i=1}^N (E_i - \bar{E})(P_i - \bar{P})}{\sqrt{\sum_{i=1}^N (E_i - \bar{E})^2 \sum_{i=1}^N (P_i - \bar{P})^2}},$$

где E – данные полученные из экспериментального набора, P – данные полученные с помощью нейронной сети, \bar{E} и \bar{P} – средние значения E и P соответственно, N – общее число данных использованных при вычислении.

Таблица 1 – Сравнение погрешностей для разных вариантов обучающего и проверочного наборов

№	Вариант подготовки данных	Обучающий набор		Проверочный набор	
		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	$\ln(\varepsilon), \ln(\dot{\varepsilon}), T$	10,183	0,996	21,343	0,996
4	$\ln(\varepsilon), \ln(\dot{\varepsilon}), T^{-1}$	21,699	0,962	29,568	0,954

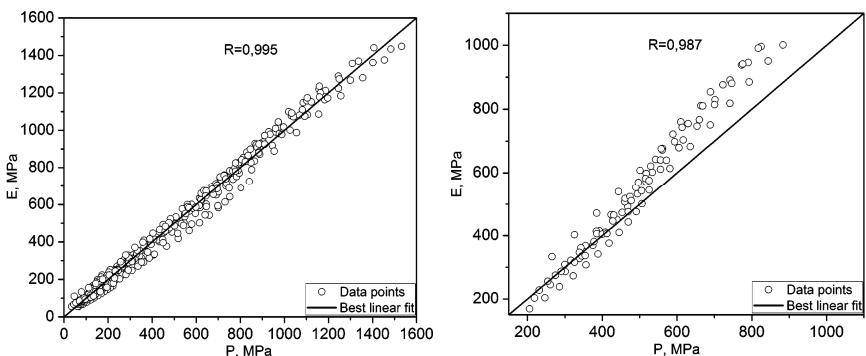


Рисунок 3 – Корреляция между экспериментальными значениями (E) и значениями полученными с помощью НС (P). Обучающий (слева) и тестовый (справа) набор № 2

Табл. 1 показывает эффективность работы модели при разных вариантах подготовки данных для обучающего и проверочного наборов. Из таблицы видно, что после обработки данных по скорости деформации логарифмической функцией результат значительно улучшается. Очень хорошо это видно

для проверочного набора. Сходимость ухудшается при применении логарифмической функции к ряду значений деформаций. Это можно объяснить тем, что в случае со скоростью деформаций логарифмическая функция создала интервалы между точками данных почти одинаковыми, а для ряда данных по деформации такого явного изменения не произошло. Полученные результаты тестирования показали, что для повышения эффективности модели, обучающие данные необходимо нормализовать и приводить к упорядоченному виду, а лучшие результаты обучения дает тренировочный набор № 2.

На рис. 4-6 показано распределение относительной погрешности при трех входных параметрах модели $(\bar{\varepsilon}_p, \ln(\dot{\varepsilon}_p), T)$. Как видно наименьшая точность аппроксимации наблюдается на границах диапазонов всех трех параметров, что является нормальным для искусственной НС. Полученные результаты показали хорошее качество обучения – средние относительные погрешности для обучающего (8,1 %) и проверочного (10,3 %) набора данных.

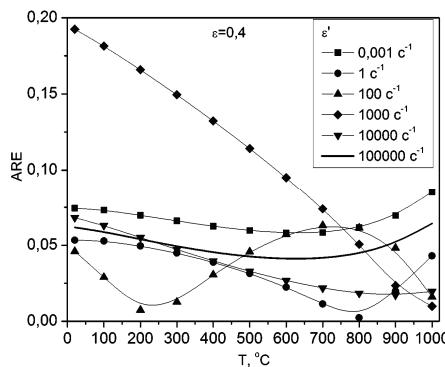


Рисунок 4 – Зависимость относительной погрешности от температуры T при деформации $\varepsilon = 0,4$ для разных скоростей деформаций $\dot{\varepsilon}'$ (набор данных № 2)

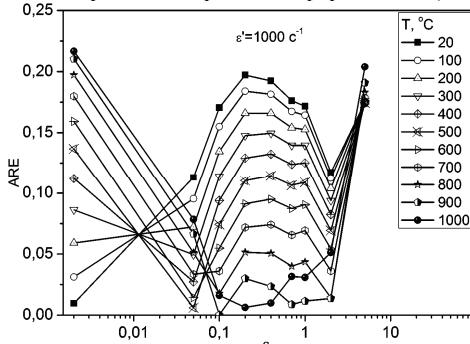


Рисунок 5 – Зависимость относительной погрешности от деформации ε при скорости деформации 1000 c^{-1} для разных температур T (набор данных № 2),
 $\dot{\varepsilon} = 1000\text{ c}^{-1}$ – проверочный набор

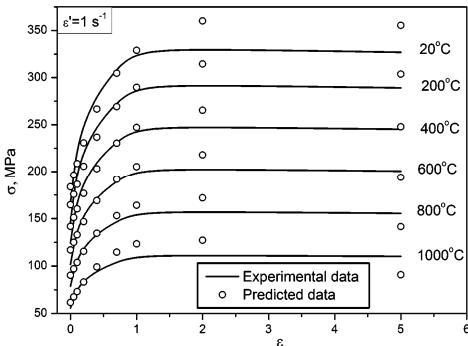


Рисунок 6 – Сходимость экспериментальных данных с полученными с помощью НС на примере семейства кривых течения стали 45 при скорости деформаций 1 s^{-1} (набор данных № 2).

9 Выводы. В работе рассмотрены особенности разработки НС-модели пластического состояния материала для широкого диапазона скоростей деформаций и температур применительно к стали 45. При обучении нейронной сети были использованы различные варианты подготовки данных для обучения. Получен лучший вариант структуры входных данных, который обеспечил высокую эффективность аппроксимации семейства кривых деформирования в широком диапазоне скоростей деформаций и температур как для обучающей выборки, так и для весьма «жесткой» проверочной выборки. Это показывает возможность успешного применения данной модели в сочетании с МКЭ при моделировании процессов высокоскоростного деформирования.

Список литературы: 1. Haj-Ali R.M., Pecknold D.A., Ghaboussi J., Voyatzis 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. Залога В.А., Криворучко Д.В., Хвостик С.Н. О выборе уравнения состояния обрабатываемого материала для моделирования процесса резания методом конечных элементов // Вісник Сумського державного університету. Серія Технічні науки. 2006. – № 12 (96). – С. 101-115. 4. 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. 5. D'Addona D., Teti R. Intelligent Material Modelling for Mild Steel Hot Working // Vimation Journal, Special Issue on Inter-active Systems in Healthcare, 2010. – ISSN 1866-4245. – С. 79-83. 6. Reddy N.S., Park C.H., Lee Y.H., Lee C.S. Neural network modelling of flow stress in Ti- 6Al-4V alloy with equiaxed and Widmanstatten microstructures // Materials Science and Technology, 2008. – Vol. 24, Nr 3. – С. 294-301. 7. 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. –Vol. 4, Nr 4. – С. 823-826. 8. 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. 9. Sanjeev Sen, Janet M. Twomey, Jamal Y. S. Ahmad Development of an Artificial Neural Network Constitutive Model for Aluminum 7075 Alloy // IERC Conference. – 2002. 10. Johnson G.R., Cook W.H. A Constitutive Model and Data for Metals Subjected to LargeStrains, High Strain Rates and

High Temperatures // Proceedings of the 7th int. Symp. On Ballistics. – 1983. – C. 541-547. **11.** Zerilli F.J., Armstrong R.W. Dislocationmechanics-based constitutive relation for material dynamics calculations // Journal of Applied Physics. – 1987. – N. 61. – C. 1816-1825. **12.** Oxley P.L. Mechanics of machining: An analytical approach to assessing machinability // Ellis Horwood Limited. – 1989. – 242 c.

Поступила в редакцию 26.09.2011