

А.О. Огородник, В.Л. Хавин, канд. техн. наук, Харьков, Украина

МЕХАНИЧЕСКАЯ МОДЕЛЬ НА ОСНОВЕ НЕЙРОННОЙ СЕТИ ДЛЯ ПРОГНОЗИРОВАНИЯ СОСТОЯНИЯ МЕТАЛЛА ПРИ ВЫСОКОСКОРОСТНОЙ ЛЕЗВИЙНОЙ ОБРАБОТКЕ

Проведено порівняльний аналіз двох підходів до моделювання пластичного стану матеріалу при обробці різанням: нейро-мережевий та напівемпіричний. Особливістю моделей є необхідність опису стану металу у широкому діапазоні пластичних деформацій, швидкостей деформацій ($1 \cdot 10^6 \text{ c}^{-1}$) та температур (20-1000 °C). Для реалізації моделі на базі нейронної мережі було використано перцептрон з одним прихованим шаром. Напівемпіричну модель було реалізовано за допомогою рівняння Джонсона-Кука. Були створені визначальні співвідношення на базі експериментальної сім'ї кривих деформування сталі 45 для проведення порівняльної характеристики ефективності моделей.

Проведен сравнительный анализ двух подходов к моделированию пластического состояния материала при обработке резанием: нейро-сетевой и полумпирический. Особенностью моделей является необходимость описания состояния металлов в широком диапазоне пластических деформаций, скоростей деформаций ($1 \cdot 10^6 \text{ c}^{-1}$) и температур (20-1000 °C). Для реализации новой модели на базе нейронной сети был использован перцептрон с одним скрытым слоем. Полумпирическая модель была реализована с помощью уравнения Джонсона-Кука. Были созданы определяющие соотношения на базе экспериментального семейства кривых деформирования стали 45 для проведения сравнительной характеристики эффективности моделей.

A comparative analysis of two approaches to material flow stress state modeling for machining was carried out: neural network and semi-empirical. The main feature of these models is necessity to describe metal state in wide range of plastic strain, strain rate ($1 \cdot 10^6 \text{ s}^{-1}$) and temperature (20-1000 °C). For model implementation based on the neural network the perceptron with one hidden layer has been used. Semi-empirical model has been realized with Johnson-Cook equation. The constitutive equations based on the experimental family of strain curves for AISI 45 were generated for the benchmark analysis of the models.

Введение. Имитационное моделирование процесса формовки и механической обработки металла является актуальной задачей, корректное решение которой позволяет добиться снижения стоимости и времени экспериментальных исследований. Методы механики сплошной среды и компьютерной механики реализованные в форме метода конечных элементов (МКЭ), широко применяются при прогнозировании механических параметров технологических операций механообработки. Эти методы в качестве составной части используют определяющие модели (constitutive models) обрабатываемого материала для имитации реальных условий деформирования материала при механообработке.

Определяющая модель (определяющее соотношение) – это модель, описывающая пластическое поведение материала через функциональную зависимость напряжений пластического течения (текущего предела текучести)

Так, в ряде публикаций последнего десятилетия [7-9] для описания свойств металлов и сплавов успешно применяются НС. В работах [10, 11] рассматриваются пути совершенствования нейросетевых моделей материала путем совершенствования способа подготовки данных, а так же варьированием внутренней структуры нейронных сетей.

Для более адекватного описания процесса пластического деформирования в широком диапазоне скоростей деформаций и температур свойственных процессу лезвийной обработки в настоящей работе предложена нейросетевая модель (НС-модель), обеспечивающая более точное описание состояния материала, чем известные классические модели.

Цель работы – разработка определяющего соотношения для материала (сталь 45) с применением НС в широком диапазоне скоростей деформаций и температур.

В работе были решены следующие задачи:

1. Выбор эффективной НС. Подбор наиболее подходящего метода обучения сети и оптимальной архитектуры.
2. Подготовка НС с помощью обучающего набора экспериментальных данных.
3. Сравнение результатов аппроксимации экспериментальных данных, полученных с помощью НС-модели, с результатами, полученными по модели Джонсона-Кука.

Особенности НС-модели. Нейронные сети несколько лет назад были использованы при моделировании металлообработки как альтернатива эмпирическим и полумпирическим математическим моделям, описывающим свойства материала. Подход получил распространение, в основном, благодаря способности моделей на основе нейронов «обучаться» существенно нелинейным связям между входными и выходными параметрами системы. Неотъемлемыми свойствами НС при моделировании пластического поведения материала по сравнению с классическими подходами являются: способность к адаптации, распределенная память, способность к обобщению и строго параллельная структура. Благодаря этим свойствам НС мало чувствительна к шумам (помехам) и обладает большой скоростью по обработке данных, что позволяет эффективно применять модели на основе НС в компьютерной механике в сочетании с методом конечных элементов (МКЭ) [12].

Архитектура нейронной сети. На рис. 1 показана общая структура выбранной нейронной сети. В процессах высокоскоростного пластического деформирования (таких как процесс резания) напряжение пластического течения материала зависит от трех параметров: деформации, скорость деформации и температуры. В используемой нейросетевой модели входной слой соответствующий этим трем параметрам (3 нейрона), а выходной слой представлен одним параметром (нейроном) – текущим пределом текучести. Используемая в работе сеть – перцептрон с последовательными связями и одним

$\bar{\sigma}_\gamma$ от эквивалентных деформаций $\bar{\epsilon}$, скоростей пластических деформаций $\dot{\bar{\epsilon}}$ и температуры T . Общий вид определяющего соотношения может быть представлен зависимостью:

$$\sigma_\gamma = \sigma_\gamma(\bar{\epsilon}, \dot{\bar{\epsilon}}, T) \tag{1}$$

Определяющие соотношения создаются на основе обработки кривых деформирования, полученных путем испытаний на одноосное растяжение (сжатие) или сдвиг.

Анализ литературы и постановка задачи. Для моделирования пластического поведения материала используются эмпирические и полумпирические соотношения.

Все известные модели основаны на ряде допущений, вызванных сложностью функциональных связей, описывающих поведение материала при широком диапазоне деформаций, скорости деформаций и температур. Успех той или иной модели, в частности, зависит от того, насколько эффективно она отображает внутренние связи рассматриваемого явления. Наибольшее распространение получили эмпирические, а в последнее время – и полумпирические зависимости. Среди них: уравнение Джонсона-Кука (Johnson-Cook) [1], уравнение Зерилли-Армстронга (Zerilli-Armstrong) [2] и уравнение Оксли (Oxley) [3]. Благодаря своей простоте (небольшое количество констант) и способности достаточно хорошо описать качественный вид кривых деформирования в широком диапазоне температур и скоростей деформации эти уравнения получили распространение в практических расчетах по имитационному моделированию процессов лезвийной обработки металлов [4].

Такие модели способны показать картину поведения материала, но не способны достаточно хорошо отобразить все многообразие его поведения, включающее существенную качественную неоднородность кривых деформирования в широком диапазоне скоростей деформаций и температур, характерных для процессов лезвийной обработки металла ($\bar{\epsilon} = 0,002-5$; $\dot{\bar{\epsilon}} = 1-100000 \text{ c}^{-1}$; $T = 20-1000 \text{ }^\circ\text{C}$) [5]. При этом известно, что влияние скорости деформации и температуры на пластическое поведение обрабатываемого материала не поддается корректному аналитическому описанию для данного технологического процесса. Это подтверждает и тот факт, что при сравнении с экспериментальными данными, в частности с экспериментальными значениями силы резания, для результатов прогнозирования наблюдается значительная погрешность.

В последние годы широкое распространение получило новое направление в области создания моделей, прогнозирующих свойства материалов на основе искусственных нейронных сетей (НС, Artificial neural network, ANN), которые зарекомендовали себя как эффективный метод аппроксимации сложных нелинейных и неявных зависимостей [5, 6].

скрытым слоем – оптимальный вариант для аппроксимации непрерывных функций [7, 8]. Скрытый слой содержит 5 нейронов.




Рисунок 1 – Архитектура нейронной сети

Структура экспериментальных данных. Экспериментальные данные по стали 45 (AISI 1045) для обучения НС задавались в табличной форме из базы данных материалов 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 [1, 100, 1000, 10000, 100000] c^{-1} , температур [20..1000] $^\circ\text{C}$ с шагом в $100 \text{ }^\circ\text{C}$.




Рисунок 2 – Семейство кривых течения стали 45 при скорости деформаций 100 c^{-1}
 На рис. 2 показан пример семейства кривых деформирования построенных по используемым табличным экспериментальным данным при скорости деформаций 100 c^{-1} для всего рассматриваемого диапазона температур. По

оси абсцисс – истинные деформации ε , по оси ординат – напряжения пластического течения σ_T .

Подготовка данных и обучение НС. Практика показала, что для достижения лучших результатов работы сети исходные данные перед обучением необходимо нормализовать. Т.е. в идеале все 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 обучающей выборки на максимальное значение соответствующего диапазона.

Методом проб для обучения НС был выбран вариант входного вектора вида: $(\varepsilon, \ln(\dot{\varepsilon}), T)$. В предыдущей работе [13] было установлено, что именно такой вариант подготовки данных является наиболее эффективным. Это можно объяснить тем, что для скорости деформаций логарифмическая функция создает равные интервалы для всей обучающей выборки по данному параметру (упорядочивает «сетку» данных).

В качестве критерия завершения процесса обучения в данной работе был использован критерий по количеству обучающих итераций. Опытным путем установлено, что до отметки 10^5 итераций погрешность при обучении уменьшается. После чего значительных изменений в качестве процесса обучения (уменьшения погрешности) не происходит.

В процессе подготовки данных было сформировано 495 набора данных. Из которых 486 (98%) было использовано для обучения, а 9 (2%) – для проверки качества работы НС. В качестве проверочного набора была выбрана кривая $\sigma = \sigma(\varepsilon)$ при $\dot{\varepsilon} = 10^3 \text{ c}^{-1}$ и $T = 500 \text{ }^\circ\text{C}$. При обучении НС-модели данная кривая была исключена.

Определяющее соотношение Джонсона-Кука. В настоящее время модель (уравнение) Джонсона-Кука чаще других применяется при имитационном моделировании процессов лезвийной обработки для представления зависимости напряжения пластического течения от деформаций, скорости деформаций и температуры. Однако известно, что корреляция данного уравнения с экспериментальными данными не удовлетворительна, в частности для широких диапазонов скоростей деформаций и температур. Уравнение Джонсона-Кука имеет следующий вид:

$$\sigma = [A + B\varepsilon^n] \cdot \left[1 + C \ln \frac{\dot{\varepsilon}}{\dot{\varepsilon}_0} \right] \cdot (1 - T_h^m) \quad (2)$$

$$T_h = \frac{T - T_{room}}{T_{melt} - T_{room}}, \quad (3)$$

261

где σ – напряжение пластического течения, ε – деформации, $\dot{\varepsilon}$ – скорость деформаций, T – температура, A, B, n, C, m – коэффициенты, которые подбираются путем минимизации среднеквадратичной погрешности между экспериментальными данными и численными значениями, полученными по уравнению Джонсона-Кука (табл. 1), $\dot{\varepsilon}_0$ – эталонная скорость пластических деформаций (принято 1 c^{-1}), T_{room} – комнатная температура ($20 \text{ }^\circ\text{C}$), T_{melt} – температура плавления исследуемого металла (для стали 45 принята $1460 \text{ }^\circ\text{C}$).

Таблица 1 – Коэффициенты для уравнения Джонсона-Кука для стали 45

Наименование коэффициента	A (MPa)	B (MPa)	n	C	m
Числовые значения	81,479	221,675	1,05	0,294	0,158

При подборе коэффициентов для уравнения Джонсона-Кука использовался тот же набор экспериментальных данных, что и при обучении НС-модели.

Проверка качества моделей. Для оценки работоспособности и качества моделей использовались статистические критерии [7-9, 12]. Эффективность работы сети и уравнения Джонсона-Кука определялась и представлялась с помощью средней относительной погрешности (average absolute relative error, AARE) и коэффициента корреляции (R):

$$AARE = \frac{1}{N} \sum_{i=1}^N \left| \frac{E_i - P_i}{E_i} \right| \times 100, \quad (4)$$

$$R = \frac{\sum_{i=1}^N (E_i - \bar{E})(P_i - \bar{P})}{\sqrt{\sum_{i=1}^N (E_i - \bar{E})^2 \sum_{i=1}^N (P_i - \bar{P})^2}}, \quad (5)$$

где E – данные 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 оценке погрешности.

В табл. 2 показана сравнительная эффективность работы двух рассматриваемых моделей материала при одинаковых исходных экспериментальных данных, используемых для формирования моделей. Как видно для обучающего набора экспериментальных данных разница в средней относительной погрешности существенна. При этом стоит отметить, что лучшие показатели дает именно НС-модель. Так, полученные результаты по НС-модели показали хорошее качество обучения – средние относительные погрешности для обу-

262

чающего (2,474%) и проверочного (1,9%) набора данных. Для проверочного набора модель на основе нейронной сети показала еще более высокую точность по сравнению с моделью Джонсона-Кука.

Таблица 2 – Сравнение погрешностей для определяющих соотношений

№	Наименование модели	Обучающий набор		Проверочный набор	
		ARRE, %	R	ARRE, %	R
1	НС-модель	2,474	0,999	1,9	0,997
2	Модель Джонсона-Кука	5,246	0,990	5,219	0,946




Рисунок 3 – Корреляция между экспериментальными значениями (E) и расчетными значениями напряжений (P) для: а) НС, б) модели Джонсона-Кука.




Рисунок 4 – Качество аппроксимации кривых деформирования стали 45 с помощью НС и моделью Джонсона-Кука: а) при скорости деформаций 10^3 c^{-1} и температуре $500 \text{ }^\circ\text{C}$, б) при скорости деформаций 10^3 c^{-1} и температуре $20 \text{ }^\circ\text{C}$.

По коэффициенту корреляции можно оценить качество аппроксимации экспериментальных данных. Из рис. 3-4 видно, что чем больше значения напряжений и деформаций, тем больше отклонение экспериментальных данных

263

от данных по модели Джонсона-Кука. Например, если в диапазоне малых значений напряжений (до 400 МПа) по модели Джонсона-Кука AARE составляет порядка 4,86 %, то при больших напряжениях (более 1000 МПа) эти значения составляют 5,6 %.

Выводы. В работе предложен основанный на нейронных сетях новый подход к моделированию пластического состояния материала в широком диапазоне скоростей деформаций и температур, соответствующих процессам лезвийной обработки.

Предложенная НС-модель обеспечивает хорошую точность аппроксимации семейства кривых деформирования, как для обучающей выборки данных, так и для проверочной выборки, в то время как широко применяемая модель Джонсона-Кука, сформированная на этом же семействе кривых деформирования, хорошо проявила себя только на отдельных диапазонах параметров (на малых деформациях и скоростях деформаций).

Полученные результаты показали возможность успешного применения НС-модели в имитационных моделях для прогнозирования выходных параметров технологических процессов лезвийной обработки.

Список использованных источников: 1. Johnson G.R Constitutive Model and Data for Metals Subjected to Large Strains, High Strain Rates and High Temperatures/ Johnson G.R., Cook W.H. A // Proceedings of the 7th int. Symp. On Ballistics. -1983. -С. 541- 547. 2. Zerilli F.J., Dislocation-mechanics-based constitutive relation for material dynamics calculations/ Zerilli F.J., Armstrong R.W. //Journal of Applied Physics. -1987. -0. 61. -С. 1816- 1825. 3. Oxley P.L. Mechanics of machining: An analytical approach to assessing machinability. // Ellis Horwood Limited. - 1989. - 242 с. 4. Залого В.А., О выборе уравнения состояния обрабатываемого материала для моделирования процесса резания методом конечных элементов / В.А. Залого, Д.В. Криворучко, С.Н. Хвостик // Вісник Сумського державного університету. Серія Технічні науки. 2006. — №12(96). — с. 101-115. 5. Hashash Y.M.A. Numerical implementation of a neural network based material / Hashash Y.M.A., Jung S., Ghaboussi J. // International journal for numerical methods in engineering, 2004 – 59 – с. 989–1005. 6. Haj-Ali R.M. G.Z. Simulated Micromechanical Models using Artificial Neural Networks / Haj-Ali R.M., Pecknold D.A., etc. // ASCE J. Eng. Mechanics, 2001 – Vol. 127, No. 7 – с. 730-738. 7. Sumantra Mandal Constitutive flow behaviour of austenitic stainless steels under hot deformation: artificial neural network modelling to understand, evaluate and predict / Sumantra Mandal, Sivaprasad P.V., etc. // Modelling Simul. Mater. Sci. Eng. 2006 – 14 – с. 1053-1070. 8. D'Addona D. Intelligent Material Modelling for Mild Steel Hot Working / D'Addona D., Tei R. // Vimation Journal, Special Issue on Interactive Systems in Healthcare, 2010 – ISSN 1866-4245 – с. 79-83. 9. Reddy N.S. Neural network modelling of flow stress in Ti–6Al–4V alloy with equiaxed and Widmanstatten microstructures. / Reddy N.S., Park C.H., etc. // Materials Science and Technology, 2008 – Volume 24, Number 3 – с. 294-301. 10. Wang B. Improvement of the Prediction Accuracy and Efficiency of Hot Strength of Austenitic Steels with Optimised ANN Training Schemes / Wang B., Kong L.X., etc. // Metals and materials international, 1998 – Volume 4, Number 4 – с. 823-826. 11. Sha, W. The use of artificial neural networks in materials science based research / Sha, W., Edwards, K. L. // Materials and Design, 2007 – Vol.28, No.6 – с. 1747-1752. 12. Sanjeev Sen Development of an Artificial Neural Network Constitutive Model for Aluminum 7075 Alloy / Sanjeev Sen, Janet M. Twomey, Jamal Y. S. Ahmad // IERC Conference – 2002. 13. Хаџин В.Л. Модель пластического состояния материала для широкого диапазона температур и скоростей деформаций на основе нейронной сети. / В.Л. Хаџин, О.О. Огородник // Вісник НТУ «ХП», - Харків: НТУ «ХП». - 2011. - №52 - 202 с.

Поступила в редакцию 07.05.2012

264