

**Перспективы применения импульсных струй жидкости для тушения газовых факелов / А. Н. Семко, М. В. Бескровная, Ю. Д. Украинский, С. А. Виноградов, И. Н. Грицына // Вісник НТУ «ХПІ». Серія: Математичне моделювання в техніці та технологіях. – Харків: НТУ «ХПІ», 2013. – №5 (979). – С. 225-232. Бібліогр.: 8 назв.**

Проведено експериментальні дослідження гасіння газового факела за допомогою імпульсних струменів рідини високої швидкості, які генеруються пороховим імпульсним водометом. Швидкість імпульсної струменя в залежності від енергії заряду в експериментах досягала 300 – 600 м/с. За допомогою лазерного безконтактного вимірювача швидкості вимірювалася швидкість голови струменя безпосередньо перед факелом, проводилося фотографування струменя. Показано, що навколо імпульсного струменя рідини високої швидкості в повітрі утворюється високошвидкісна хмара бризок великого поперечного перерізу, яке ефективно збиває полум'я газового факела на відстанях 5 – 20 м від установки.

**Ключові слова:** газовий факел, імпульсна струминка, пороховий водомет, внутрішня балістика.

Experimental studies of putting out of gas blowout by means of high-speed impulse liquid jets generated by a powder pulse-jet water canon have been carried out. The speed of impulse jet depending on charge energy ranged in the experiments from 300 to 600 m/s. The speed of the head section of the jet has been measured directly before the torch by means of a non-contact laser speed measuring device, the jet photographing has been carried out. It has been shown that around the high-speed liquid impulse jet in the air is formed a high-speed cloud of large cross-section splashes that efficiently knocks down the flame of the gas torch at distances of 5 – 20 m from the unit.

**Key words:** gas torch, flash squirt, water cannon powder, internal ballistics.

УДК 539.1

**В. Л. ХАВІН**, канд.техн. наук, проф., НТУ «ХПІ»;

**Л. В. АВТОНОМОВА**, канд. техн. наук, пров. наук. співр., НТУ «ХПІ»;

**С. І. МАРУСЕНКО**, наук. співр., НТУ «ХПІ»

## **ЗАСТОСУВАННЯ НЕЙРОМЕРЕЖЕВОЇ МОДЕЛІ ДЛЯ ПРОГНОЗУВАННЯ СТАНУ МАТЕРІАЛУ ПРИ ВИСОКОШВИДКІСНОМУ ДЕФОРМУВАННІ**

Представлено нейромережеву модель (НМ-модель) визначального співвідношення пластичного стану матеріалу для широкого діапазону деформацій, швидкостей деформацій і температур. Реалізацію моделі здійснено за допомогою нейронної мережі – 3-и шарового перцептрону з одним прихованим прошарком. Отримано оптимальну архітектуру, проведено навчання НМ-моделі на базі експериментальних даних для сталі 45. Для перевірного набору даних проведено порівняння з результатами, отриманими за рівнянням Джонсона-Кука.

**Ключові слова:** визначальне співвідношення., широкий діапазон деформацій, швидкостей деформацій і температур, нейромережева модель, перцептрон.

**Вступ.** Прогнозуюче моделювання процесів металообробки (зокрема, процесів різання металів і сплавів), що реалізовується за допомогою комп'ютерних розрахунків, набуло широкого поширення лише в останнє десятиліття. Цей підхід дозволяє проводити розрахунок параметрів процесу за порівняно невеликий час, з невеликими затратами і з достатньою для прак-

тики точністю. Але для ефективнішого застосування відповідного програмного забезпечення необхідно вдосконалення підходів і моделей, що вживаються, наприклад, для врахування властивостей матеріалу, що оброблюється, в реальному діапазоні параметрів обробки.

Опис властивостей матеріалу, що оброблюється, при імітаційному чисельному моделюванні процесів металообробки здійснюється за допомогою *визначального співвідношення (моделі)*, тобто математичної функціональної залежності напруженості пластичної течії (поточної межі текучості)  $\sigma_y$  від деформації  $\varepsilon$ , швидкості деформації  $\dot{\varepsilon}$  і температури  $T$ . Загальний вигляд визначальної моделі для одноосного напруженого стану представляється залежністю:

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

і тоді для складного напруженого стану умова переходу до пластичного стану визначається залежністю:

$$\bar{\sigma}_y(\bar{\varepsilon}, \bar{\dot{\varepsilon}}, T) = \bar{\sigma}_y(\varepsilon, \dot{\varepsilon}, T), \quad (2)$$

де  $\bar{\sigma}_y$  – еквівалентна напруга;  $\bar{\varepsilon}$  – еквівалентна деформація;  $\bar{\dot{\varepsilon}}$  – швидкість еквівалентної деформації.

Визначальні співвідношення (1) створюються на основі аналізу і обробки кривих деформації, отриманих шляхом випробувань на одноосне розтягування і (або) стискання в заданому діапазоні швидкостей деформацій і температур.

**Аналіз літератури і постановка задачі.** В якості визначальних моделей в даний час у практиці розрахунків використовуються емпіричні і напівемпіричні співвідношення. Всі відомі моделі засновані на ряді припущень, пов'язаних зі складністю функціональних зв'язків, що описують поведінку матеріалу в широкому діапазоні деформацій, швидкостей деформацій і температур. Найбільш відомі залежності – це *рівняння Джонсона-Кука (Johnson-Cook)* [1], *рівняння Зерілли-Армстронга (Zerilli-Armstrong)* [2] і *рівняння Окслі (Oxley)* [3].

Відомі моделі в змозі адекватно описати якісну картину поведінки матеріалу, але не здатні достатньо добре відобразити все різноманіття змін його властивостей. Наприклад, врахувати істотну якісну неоднорідність кривих деформацій в широкому діапазоні деформацій, швидкостей деформацій і температур, що характерні для процесів лезової обробки металів ( $\varepsilon = 0,002^{-5}$ ;  $\dot{\varepsilon} = 1-100000 \text{ c}^{-1}$ ;  $T = 20-1000^0 \text{ C}$ ) [5].

Останніми роками поширення набув новий напрямок в області створення моделей, що прогнозують властивості матеріалів на основі штучних нейронних мереж (НМ, ANN), які зарекомендували себе як ефективний метод апроксимації складних нелінійних і неявних залежностей [5, 6].

**Мета роботи** – розробка на базі нейронної мережі визначальної моделі стану матеріалу (НМ-моделі) для широкого діапазону швидкостей, деформацій і температур і вибір оптимальної архітектури моделі.

У роботі були вирішені наступні задачі.

1. Вибір типу НМ. Підбір методу навчання НМ і оптимальної архітектури.

2. Підготовка НМ за допомогою навчального набору експериментальних даних.

3. Порівняння точності апроксимації експериментальних даних, отриманих за допомогою НМ-моделі із результатами, отриманими за моделлю Джонсона – Кука.

У даній роботі для НМ-моделі, що визначає стан матеріалу, була вибрана нейронна мережа – 3-и шаровий перцептрон з одним прихованим про-шарком.

У даному класі НМ (багат шарові перцептрони) використовуються *комірки-нейрони*, що перетворюють вхідний вектор  $X$  в скалярну відповідь – вихід  $S$ , залежний від лінійної комбінації вхідних змінних:

$$S = f\left(\sum_{i=1} w_i^{(2)} x_i + w_0\right) \equiv f\left(\sum_{i=0} w_i^{(2)} x_i\right), \quad (3)$$

де  $x_0 = 0$ , а вираз на виході з нейрона визначається за допомогою однієї з найбільш ефективних функцій активації, що вживаються, у вигляді гіпербололічного тангенса:

$$y = \tanh S \quad (4)$$

або у вигляді *сигмоїдальної функції*:

$$y = 1 / \left(1 + e^{-\lambda S}\right), \quad (5)$$

де  $\lambda$  – константа.

Відповідно до рекомендацій, приведених в роботах [5-12], навчальні вхідні дані слід задавати по можливості із більш рівномірним кроком і в нормалізованому вигляді, розташовуючи дані в діапазоні  $[-1;1]$ ,  $[0;1]$  або  $[0,1;0,9]$ .

Для цієї мети застосовуються різні нормалізуючі залежності для вхідних параметрів  $x$ , наприклад, такого вигляду:

$$\bar{x}_j = 2(x_j - x_{\min}) / (x_{\max} - x_{\min}) - 1, \quad (6)$$

$$\bar{x}_j = (x_j - x_{\min}) / (x_{\max} - x_{\min}) \quad (7)$$

або інші.

Для навчання найчастіше використовується *метод* (алгоритм) *зворотного розповсюдження помилки*, що забезпечує мінімум сумарної середньоквадратичної помилки  $E^{(n)}$ :

$$E^{(n)} = \sum (d_j^{(n)} - y^{(n)})^2 / 2 \Rightarrow \min, \quad (8)$$

або (та) середньої помилки  $E_{av}$ :

$$E_{av}^{(n)} = \left(\sum_{j=1}^N E^{(n)}\right) / N \Rightarrow \min, \quad (9)$$

де  $n$  – кількість ітерації процесу навчання;  $N$  – кількість наборів навчальних даних;  $d_j^{(n)}$  – еталонне значення виходу для  $j$ -го нейрону на  $n$ -ій ітерації.

Базова ідея методу зворотного розповсюдження помилки полягає у визначенні ступеня впливу зміни вагового коефіцієнта  $w_{ij}^{(n)}$  на величину помилки  $E^{(n)}$  у вигляді похідної  $\partial E^{(n)} / \partial w_{ij}^{(n)}$ , де  $w_{ij}^{(n)}$  – це вага зв'язку між  $i$ -им і  $j$ -им

нейронами на  $n$ -ій ітерації. На основі зазначених часткових похідних помилки проводиться мінімізація  $E^{(n)}$  з використанням *методу градієнта*, де крок за варіюваними ваговими коефіцієнтами визначається залежністю:

$$\Delta w_{ji}^{(n)} = -\alpha (\partial E^{(n)} / \partial w_{ji}^{(n)}), \quad (10)$$

$\alpha$  – коефіцієнт швидкості навчання.

В якості критерію збіжності процесу навчання в даній роботі використовувалося значення середньоквадратичної помилки  $E_{RMC}$  між еталонним і обчисленими вихідними значеннями:

$$E_{RMC} = \frac{1}{N} \sum_{i=1}^N \sqrt{\frac{1}{p} \sum_{j=1}^p (d_{ij} - y_{ij})^2}, \quad (11)$$

де  $N$  – кількість тренувальних (тестових) даних;  $p$  – кількість вихідних параметрів, у мережі, що використовується в роботі,  $n = 1$ .

Якість роботи мережі також визначалася *коефіцієнтом кореляції*  $R$ :

$$R = \sum_{i=1}^N \{(d_i - \bar{d})(y_i - \bar{y})\} / \sqrt{\sum_{i=1}^N (d_i - \bar{d})^2 \sum_{i=1}^N (y_i - \bar{y})^2}, \quad (12)$$

і *середньою абсолютною відносною помилкою*:

$$AARE = \frac{1}{N} \sum_{i=1}^N |(d_i - y_i) / d_i| \times 100\%, \quad (13)$$

де  $d$  – експериментальне (відоме) значення;  $y$  – прогнозоване значення відповідної вихідної величини;  $\bar{d}$  та  $\bar{y}$  – середні значення  $d$  і  $y$  відповідно;  $N$  – кількість даних, що розглядаються.

**Архітектура мережі.** На рис.1 показано структуру нейронної мережі [13, 14]. У процесах високошвидкісної пластичної деформації (наприклад, процесу різання металу) напруження пластичної течії матеріалу залежить від трьох основних параметрів: деформації, швидкості деформації і температури. У НМ-моделі, що використовується, вхідний прошарок відповідає цим параметрам, а вихідний прошарок представлений одним параметром (*нейроном*) – поточною межею текучості.

Кількість нейронів у вхідному і вихідному прошарках задається кількістю вхідних (3) і вихідних (1) параметрів. З метою визначення оптимальної структури НМ – моделі (кількість нейронів в прихованому прошарку) було застосовано метод оцінки якості роботи мережі за значенням середньоквадратичної помилки  $E_{RMC}$  (11). Вплив кількості нейронів в прихованому прошарку на величину  $E_{RMC}$  показано на рис. 2. Видно, що помилка  $E_{RMC}$  практично досягає мінімуму вже на рівні 5 нейронів в прихованому прошарку, внаслідок чого в даній роботі для моделювання використовувався перцептрон з 3-ма прошарками та 5-ма нейронами в прихованому прошарку.

Формування НМ-моделі на базі визначального співвідношення вигляду (1) було здійснене за допомогою опису кривих деформування сталі AISI-1045 (сталь 45, СК45).




Рис. 1 – Архітектура нейронної мережі.




Рис. 2 – Залежність середньоквадратичної помилки від кількості нейронів в прихованому прошарку.

Вихідні дані були отримані на основі обробки матеріалів, представлених в базі даних пакету DEFORM V.10. Були використані дані в діапазоні деформацій

$$\varepsilon = 0,002 - 1,0, \quad \dot{\varepsilon} = 10^{-3} - 10^{-4} c^{-1},$$

$$T = 20 - 1000^0 C.$$

Проводилася лінійна екстраполяція до значення швидкості  $\dot{\varepsilon} = 10^5 c^{-1}$ , значення температури  $T = 1200^0 C$  і до деформацій  $\varepsilon = 4,0$ , оскільки експериментальні дані для  $\dot{\varepsilon} > 10^4 c^{-1}$  і  $T > 1000^0 C$  у літературі відсутні.

Експериментальні дані по сталі 45 (AISI 1045) для навчання НМ задавалися шляхом відцифрування відповідних кривих деформування. Дані представлені для наступних деформацій [0.002, 0.05, 0.1, 0.4, 0.7, 1, 2, 4], швидкостей деформацій [1,100, 1000, 10000, 100000]  $c^{-1}$ , температур [20.1200]  $^0 C$  з кроком в  $100^0 C$ .

**Підготовка даних і навчання НМ.** Практика показала, що для досягнення кращих результатів роботи мережі початкові дані перед навчанням необхідно нормалізувати, що здійснювалося в роботі діленням всіх значень навчальної вибірки на максимальне значення відповідного параметра.

Для навчання НМ був вибраний варіант вхідного вектору вигляду  $(\varepsilon, \ln(\dot{\varepsilon}), T)$ . Для швидкості деформації логарифмічна функція створює близькі інтервали для всієї навчальної вибірки по даному параметру (упорядковує «сітку» даних).

В якості критерію завершення процесу навчання в даній роботі був ви-

користаний критерій по кількості навчальних ітерацій. Експериментальним шляхом встановлено, що до відмітки  $10^5$  ітерацій похибка при навчанні зменшується. Після чого значних змін в якості процесу навчання (зменшення похибки) не відбувається.

В процесі підготовки даних було сформовано 495 наборів даних. З яких 486 (98%) було використано для навчання, а 9 (2%) – для перевірки якості роботи НМ. В якості перевірного набору була вибрана експериментальна залежність  $\sigma = \sigma(\varepsilon)$  при  $\dot{\varepsilon} = 10^3 \text{ c}^{-1}$  і  $T = 500^\circ \text{C}$ . При навчанні НМ-моделі дана залежність була виключена.

Для оцінки ефективності НМ-моделі було проведено порівняння з результатами, що були отримані за визначальним співвідношенням Джонсона-Кука [1]. Рівняння Джонсона-Кука частіше за інші співвідношення застосовується при імітаційному моделюванні процесів різання металу. Рівняння Джонсона-Кука має наступний вигляд:

$$G_y = (A + B\varepsilon^n) \left[ 1 + C \ln \left( \frac{\dot{\varepsilon}}{\dot{\varepsilon}_0} \right) \right] \left[ 1 - (T^*)^m \right], \quad T^* = \frac{T - T_{room}}{T_{melt} - T_0}, \quad (14)$$

де  $\dot{\varepsilon}_0$  – еталонна швидкість деформації ( $\dot{\varepsilon}_0 = 1 \text{ c}^{-1}$ );  $T_{room}$  – кімнатна температура ( $20^\circ \text{C}$ );  $T_{melt}$  – температура плавлення ( $1460^\circ \text{C}$ );  $A, B, C, n, m$  – константи, що підбираються на основі експериментальних даних. У цій роботі константи були отримані шляхом мінімізації середньоквадратичної похибки між експериментальними даними і чисельними значеннями, що отримуються за залежністю (14). Для пошуку констант рівняння (14) був використаний той же набір експериментальних даних і критерій точності моделі, що і в алгоритмі зворотного розповсюдження помилки при навчанні НМ-моделі.

**Порівняння якості моделей.** Для оцінки якості моделей використовувалися відомі статистичні критерії [7-9, 12]. Ефективність роботи НМ-моделі в порівнянні з рівнянням Джонсона-Кука визначалася за коефіцієнтом кореляції  $R$  (12) і середньою відносною похибкою  $AARE$  (13).

У табл. 1 приведені значення середньої відносної помилки і коефіцієнта кореляції для НМ-моделі і рівняння Джонсона-Кука. Видно, що для одного і того ж набору навчальних даних відмінність в середній відносній похибці істотна. НМ-модель показала кращу точність не лише для навчального набору, але ще вищу точність для перевірного набору даних.

Таблиця 1 – Порівняння помилок

№	Назва моделі	Навчальний набір		Перевірочний набір	
		ARRE, %	R	ARRE, %	R
1	НМ-модель	2,474	0,999	1,9	0,997
2	Модель Джонсона-Кука	5,246	0,990	5,219	0,946

На рис.3 показана кореляція між експериментальними  $\sigma_E$  і розрахованими  $\sigma_P$  значеннями напруження пластичної течії для рівнів напруження 600-1500 МПа. Видно, що для високих рівнів напружень пластичної течії (також як і для великих значень швидкостей деформацій  $\dot{\varepsilon} > 10^3 \text{ c}^{-1}$ ) точність

НМ-моделі суттєво вища за модель Джонсона-Кука. Наприклад, якщо в діапазоні напруження до 600 МПа *AARE* для рівняння Джонсона-Кука складає 4,8%, то при напруженні більш 600 МПа – 5,85%. Точність НМ-моделі практично не залежить від рівня напруження і складає для усього діапазону близько 2,5%.

**Висновки.** У роботі представлено заснований на штучній нейронній мережі (персептрон Хебба) підхід до моделювання стану пластичного матеріалу в широкому діапазоні деформацій, швидкостей деформацій і температур (НМ-модель).

Вибрано оптимальну архітектуру нейронної мережі, шляхом мінімізації середньоквадратичної помилки визначена оптимальна кількість нейронів в прихованому прошарку НМ-моделі.

На основі експериментальних даних по кривих деформування сталі AISI-1045 (сталь 45) із пакету DEFORM. V10 проведено навчання НМ-моделі і проведено порівняння з результатами, отриманими по рівнянню Джонсона-Кука, яке відповідає цьому ж набору даних.

Запропонована НМ-модель забезпечує хорошу точність апроксимації сімейства кривих деформування як для навчального набору даних, так і для контрольного набору даних. В той час, як модель Джонсона-Кука, сформована на тому ж масиві даних, добре виявляла себе лише в діапазоні порівняно невеликих деформацій, швидкостей деформацій і напружень.




Рис. 3 – Кореляція між експериментальними ( $\sigma_E$ ) і розрахованими ( $\sigma_P$ ) значеннями напружень для: *a* НМ-моделі, *б* моделі Джонсона-Кука.

Отримані результати показують хорошу перспективу застосування визначальних співвідношень на базі НМ-моделей в імітаційному моделюванні і прогнозуванні параметрів стану процесів механообробки.

**Список літератури:** 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., Dislocationmechanics-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. Залозга В.А. О выборе

уравнения состояния обрабатываемого материала для моделирования процесса резания методом конечных элементов / В.А. Залоза., 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., Teti 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.** Хавін В.Л. Модель пластического состояния материала для широкого диапазона температур и скоростей деформаций на основе нейронной сети. / В.Л. Хавін, О.О. Огородник // Вісник НТУ «ХПІ», - Харків: НТУ «ХПІ», – 2011. – №52 – 202 с. **14.** Giorleo, R. Teti, V. Prisco, D.D'Addona Merging neural network material rheological behaviour modelling with FEM simulation of orthogonal metal cutting. Machining science and Technology and International Journal, – 2003, – V.7, – №36 – pp. 401 – 417. **15.** K.Hornik, M. Stinchcombe, H. White. Neural Networks, – 1998, – V.2, – pp. 359 – 366.

Надійшла до редколегії 20.02.2013

---

УДК 539.1

**Застосування нейромережевої моделі для прогнозування стану матеріалу при високошвидкісній деформації / В.Л. Хавін, Л. В. Автономова, С.І. Марусенко // Вісник НТУ «ХПІ». Серія: Математичне моделювання в техніці та технологіях. – Харків: НТУ «ХПІ», 2013. – №5 (979). – С. 232-239. Бібліогр.: 15 назв.**

Представлена нейросетевая модель (НС-модель) определяющего соотношения пластического состояния материала для широкого диапазона деформаций, скоростей деформаций и температур. Реализация модели осуществлена при помощи нейронной сети – 3-х слойного персептрона с одним скрытым слоем. Получена оптимальная архитектура, проведено обучение НС-модели на базе экспериментальных данных для стали 45. Для проверочного набора данных проведено сравнение с результатами, полученными по уравнению Джонсона-Кука.

**Ключевые слова:** определяющее соотношение, широкий диапазон деформаций, скоростей деформаций и температур, нейросетевая модель, персептрон.

The neural network's model (NN-model) of determining equations of the plastic state of material is in-process presented for the wide range of deformations, speeds of deformations and temperatures. Realization of model is carried out through the neural network - 3-th layer of perseptron with one by the hidden layer. It is got optimum architecture, teaching of NN-model is conducted on the base of experimental information for steel 45. For the verification set of data comparing is conducted to the results has been realize with Johnson-Kuk equation.

**Keywords:** determining equations, wide range of deformations, speeds of deformations and temperatures, neural network's model, perseptron.