

Определение упругих и диссипативных свойств материалов с помощью сочетания метода конечных элементов и комплекснозначных искусственных нейронных сетей^{*}

А. Н. Соловьёв, Нгуен Зуи Чыонг Занг

Рассматривается применение комплекснозначных искусственных нейронных сетей (КИНС) в обратной задаче идентификации упругих и диссипативных свойств деформируемого твёрдого тела. Дополнительной информацией для решения обратной задачи являются компоненты вектора смещений, измеренные в наборе точек на границе тела (позиционное измерение), совершающие гармонические колебания в области первой резонансной частоты. Процесс измерения смещений в работе моделируется расчётом в конечноэлементном пакете ANSYS, построением амплитудно-частотных характеристик (АЧХ) смещений и выбором их значений для некоторого набора частот (частотное измерение). В приведённом численном примере исследуются вопросы точности идентификации модуля упругости и добротности материала в зависимости от числа точек измерения и их расположения, а также от архитектуры нейронной сети и длительности процесса её обучения, который осуществляется с помощью алгоритма комплекснозначного обратного распространения ошибки (КОР).

Ключевые слова: комплекснозначные искусственные нейронные сети, идентификация механических свойств, метод конечных элементов.

Введение. В настоящее время искусственные нейронные сети (ИНС) [1] широко применяются в различных областях науки. В механике они используются для решения коэффициентных и геометрических обратных задач. Так, применению ИНС в задачах неразрушающего контроля посвящены работы [2–6], а определению механических свойств твёрдых тел — работы [7–11]. В начале 90-х годов прошлого столетия в работах Т. Nitta [12, 13] были предложены КИНС, которые в настоящее время широко используются для решения прикладных задач [14–16]. КИНС, параметры которых (веса, пороговые значения, входы и выходы) являются комплексными числами, применяются в различных областях современной техники, таких как оптоэлектроника, воспроизведение изображений, синтез речи, машинное зрение, дистанционный сбор данных, квантовые аппараты, пространственно-временной анализ физиологических нейронных аппаратов и систем. Применение КИНС в задачах механики является новой областью исследований, которая начала развиваться только в последние годы.

В настоящей работе КИНС применяется к решению обратной коэффициентной задачи идентификации упругих (модуль Юнга) и диссипативных (добротность) свойств деформируемого твёрдого тела. Дополнительная информация для решения этой обратной задачи связана с измерением поля смещения на границе тела (в дискретном наборе точек), совершающего гармонические колебания в окрестности первой резонансной частоты. В приведённом ниже примере исследуются вопросы точности идентификации механических свойств материала в зависимости от числа точек измерения и их расположения, а также от архитектуры нейронной сети и длительности (количества эпох) процесса её обучения, который осуществляется с помощью алгоритма КОР.

Постановка обратной задачи идентификации механических свойств. Рассматриваются установившиеся гармонические колебания прямоугольной области ($a \times b$) с круговой частотой ω в рамках плоской задачи теории упругости (рис. 1). Прямоугольник закреплён по левой боковой стороне S_u , в правом нижнем углу действует вертикальная сила амплитуды F_0 , остальная грани-

* Работа выполнена при частичной финансовой поддержке РФФИ (гранты № 13-01-00196-а, 13-01-00943-а).

ца S_t свободна от механических напряжений. Механические свойства материала описываются модулем Юнга E , коэффициентом Пуассона ν и добротностью Q .

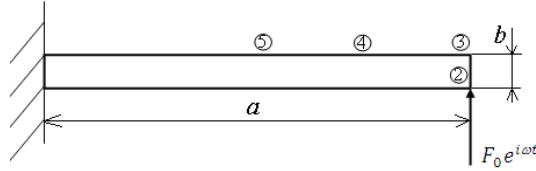


Рис. 1. Модель тела с номерами точек измерения АЧХ смещений

Уравнения колебаний тела имеют вид [18]:

$$\begin{aligned}\sigma_{kj,j} &= -\rho(\omega^2 - i\omega\alpha)u_k, \quad k, j = 1, 2, \\ \sigma_{kk} &= c_{kj}(1 + i\omega\beta)\varepsilon_{jj}, \quad \sigma_{12} = c_{44}(1 + i\omega\beta)\varepsilon_{12}, \quad \varepsilon_{kj} = \frac{1}{2}(u_{k,j} + u_{j,k}).\end{aligned}\quad (1)$$

Границные условия предполагают наличие сосредоточенной силы в точке 2 (рис.1) и однородные условия на остальной границе:

$$u_k|_{S_u} = 0, \quad \sigma_{kj}n_j|_{S_t} = 0. \quad (2)$$

Дополнительной информацией для решения обратной задачи являются смещения u_k , измеренные в точках 2–5 (рис. 1):

$$u_1 = U_{mr} + iU_{mi}, \quad u_2 = V_{mr} + iV_{mi}, \quad m = 2, 3, 4, 5, \quad (3)$$

где σ_{kj} , ε_{kj} — компоненты тензоров напряжений и деформаций соответственно; ρ — плотность.

Коэффициенты упругости соответствуют изотропному телу $c_{11} = c_{22} = \lambda + 2\mu$, $c_{12} = c_{21} = \lambda$, $c_{44} = \mu$, λ , μ — коэффициенты Ламе. Частота колебаний ω совпадает с первой собственной частотой резонанса для тела, в котором не учитывается диссипация механической энергии. Коэффициенты α и β , характеризующие диссипацию, вычисляются по методике, приведённой в [17].

Архитектура КИНС. В качестве инструмента решения обратной задачи идентификации механических свойств упругого тела в настоящей работе используется КИНС (на рис. 2).

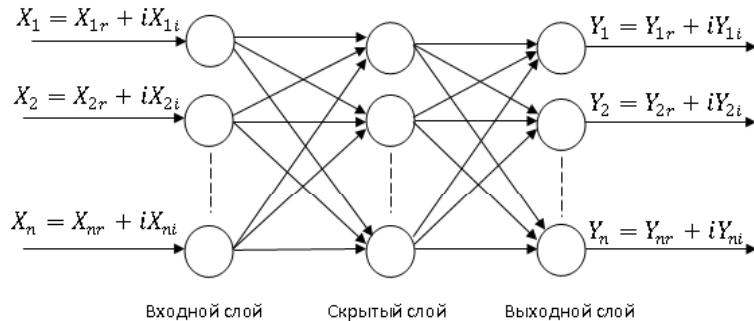


Рис. 2. Архитектура КИНС

Рассмотрим КИНС, состоящую из 3 слоёв: входной слой, скрытый слой, выходной слой (рис. 2).

Набор весовых коэффициентов (W , \tilde{W}) показывает связи между данным нейроном и всеми нейронами предыдущего слоя. Причём, каждый весовой коэффициент является комплексно-значным. Процесс обучения сети состоит в следующем:

1. Определяется случайная начальная конфигурация весов с равномерным распределением действительной и мнимой части в пределах $(-1,0, 1,0)$.

2. Входной набор данных ($X_1 = X_{1r} + iX_{1i}$, $X_2 = X_{2r} + iX_{2i}$, $X_n = X_{nr} + iX_{ni}$), на котором сеть должна быть обучена, вводится во входной слой сети, затем вычисляются выходные данные.

3. При сравнении полученных данных и известных выходных данных (для рассматриваемого входного набора) вводится вектор ошибки, квадратичная невязка между полученными и известными (опытными) данными:

$$Y_n = \sum_m W_{nm} X_m = X + iY = Z, \quad (4)$$

$$O_n = F_c(z) + iF(y) = \frac{1}{1 + \exp(-x)} + i \frac{1}{1 + \exp(-y)}, \quad (5)$$

$$E_p = \left(\frac{1}{2} \right) \sum_{n=1}^N |T_n - O_n|^2 = \frac{1}{2} \sum_{n=1}^N \left(|\operatorname{Re}(T_n) - \operatorname{Re}(O_n)|^2 + |\operatorname{Im}(T_n) - \operatorname{Im}(O_n)|^2 \right), \quad (6)$$

где W_{nm} — вес связи нейронов с номерами n и m ; X_m — входной сигнал от нейрона m ; F — сигмовидная функция; E_p — ошибка для выходного слоя; O_n — активность данного узла; T_n — требуемое выходное значение.

4. Вектор ошибки используется при модифицировании весовых коэффициентов выходного слоя, величина ошибки уменьшается при повторной подаче того же набора входных данных:

$$W_{nm} = W_{nm} + \Delta W_{nm} = W_{nm} + \overline{H}_m \Delta \lambda_n, \quad (7)$$

$$\Delta \lambda_n = \varepsilon \left\{ \operatorname{Re}[\delta^n] (1 - \operatorname{Re}[O_n]) \operatorname{Re}[O_n] + i \operatorname{Im}[\delta^n] (1 - \operatorname{Im}[O_n]) \operatorname{Im}[O_n] \right\}, \quad (8)$$

где λ_n — порог нейронов входных слоёв сети с номером n ; $\delta^n = T_n - O_n$ — обозначение ошибки между фактическим и целевым значениями выходных нейронов; H_m — выходы из скрытых нейронов.

5. На следующем шаге весовые коэффициенты скрытого слоя модифицируются аналогично предыдущим. Затем сравниваются выходные сигналы нейронов скрытого слоя и входные сигналы нейронов выходного слоя. В результате такого сравнения формируем векторы ошибки для скрытого слоя:

$$\tilde{W}_{lm} = \tilde{W}_{lm} + \Delta \tilde{W}_{lm} = \tilde{W}_{lm} + \overline{I}_l \Delta \theta_m, \quad (9)$$

$$\begin{aligned} \Delta \theta_m &= \varepsilon \left\{ \left((1 - \operatorname{Re}[H_m]) \operatorname{Re}[H_m] \sum_n (\operatorname{Re}[\delta^n] (1 - \operatorname{Re}[O_n]) \operatorname{Re}[O_n] \operatorname{Re}[W_{nm}] + \right. \right. \\ &\quad \left. \left. + \operatorname{Im}[\delta^n] (1 - \operatorname{Im}[O_n]) \operatorname{Im}[O_n] \operatorname{Im}[W_{nm}]) \right) - \right. \\ &\quad \left. - i \varepsilon \left\{ \left((1 - \operatorname{Im}[H_m]) \operatorname{Im}[H_m] \sum_n (\operatorname{Re}[\delta^n] (1 - \operatorname{Re}[O_n]) \operatorname{Re}[O_n] \operatorname{Im}[W_{nm}] - \right. \right. \right. \\ &\quad \left. \left. \left. - \operatorname{Im}[\delta^n] (1 - \operatorname{Im}[O_n]) \operatorname{Im}[O_n] \operatorname{Re}[W_{nm}]) \right) \right\}, \right. \end{aligned} \quad (10)$$

где \tilde{W}_{lm} — вес между входными и скрытыми нейронами с номерами l и m ; I_l — выходы из входных нейронов; θ_m — пороги нейронов скрытых слоёв сети.

6. Сеть обучается путём предъявления каждого входного набора данных и последующего обратного распространения ошибки. Такой цикл повторяется много раз. Обучение заканчивается при достижении для каждого из обучающих образов значения функции ошибки, не превосходящего некоторого заданного значения ε , либо после максимально допустимого числа итераций (эпох).

После достаточного обучения сеть способна моделировать функцию, связывающую значения входных и выходных переменных, и такая сеть может быть использована для прогнозирования выходных значений, то есть решения обратной задачи идентификации.

Применение КИНС к задаче идентификации модуля Юнга и добротности. Для идентификации модуля Юнга и добротности используется описанная выше КИНС, в которой эти параметры являются выходными данными. Входными данными являются амплитуды смещений (3), измеренные на поверхности тела. Для обучения КИНС составляется набор входных и выходных данных, первым шагом при его формировании является расчёт собственных резонансных частот, затем проводится расчёт установившихся колебаний для тела на этих частотах или в их окрестности с учётом диссипации механической энергии.

На рис. 1 показаны точки 2, 3, 4, 5, в которых проводятся измерения амплитуд перемещений. В работе натурный эксперимент заменился численным расчётом в конечно-элементном пакете ANSYS. На рис. 3 представлена амплитудно-частотная характеристика вертикального смещения в точке 2 в окрестности первого резонанса.

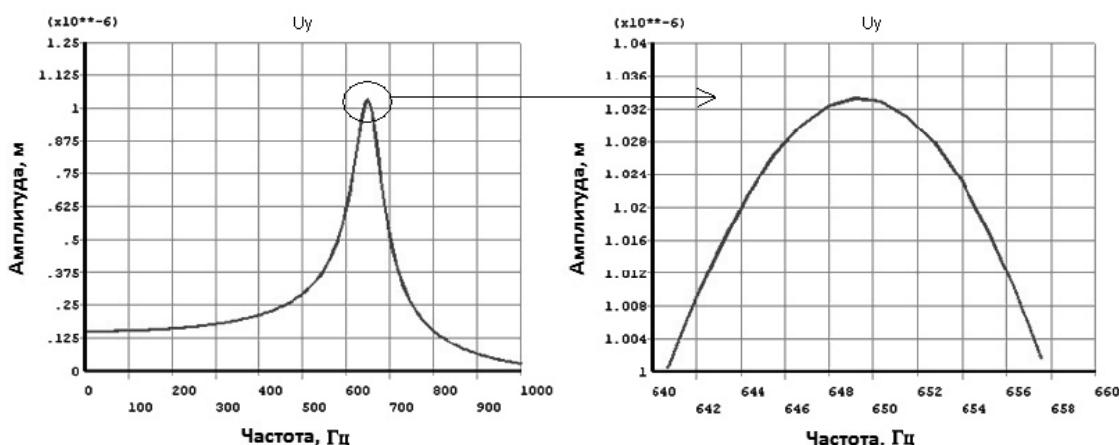


Рис. 3. Амплитудно-частотная характеристика смещения U_y , измеренная в точке 2

В табл. 1 представлены входные и выходные данные для «измерений» в точке 2.

Таблица 1

Пример данных из задач модального и гармонического анализа

№	входные данные		ω	выходные данные, м			
	E , Па	Q		U_{2r}	U_{2i}	V_{2r}	V_{2i}
1	5×10^9	10	206,35	$4,82 \times 10^{-7}$	$-5,2 \times 10^{-6}$	$1,09 \times 10^{-6}$	$-7,3 \times 10^{-5}$
2	10×10^9	20	291,83	$2,41 \times 10^{-7}$	$-2,6 \times 10^{-6}$	$5,46 \times 10^{-7}$	$-3,6 \times 10^{-5}$
3	15×10^9	30	357,41	$1,60 \times 10^{-7}$	$-1,7 \times 10^{-6}$	$3,64 \times 10^{-7}$	$-2,4 \times 10^{-5}$
4	20×10^9	40	412,7	$1,20 \times 10^{-7}$	$-1,3 \times 10^{-6}$	$2,73 \times 10^{-7}$	$-1,8 \times 10^{-5}$
5	25×10^9	50	461,42	$9,64 \times 10^{-7}$	-1×10^{-6}	$2,18 \times 10^{-7}$	$-1,5 \times 10^{-5}$

В случае одной точки позиционного измерения и n точек измерения на АЧХ, КИНС имеет n комплекснозначных входных нейронов: $U_{x_r1} + iU_{x_i1}$, $U_{x_r2} + iU_{x_i2}$, ..., $U_{x_m} + iU_{x_in}$, $U_{y_r1} + iU_{y_i1}$, $U_{y_r2} + iU_{y_i2}$, ..., $U_{y_m} + iU_{y_in}$ и один выходной нейрон $E + iQ$.

Составлено X (200, 300, 500) векторов данных, 90 % из которых используются для обучения, 10 % для тестирования. Затем проводятся компьютерные эксперименты, выполненные с помощью КИНС. Результаты обучения и тестирования представлены в табл. 2–6.

На рис. 4 представлены результаты тестирования на 50 примерах (идентификации модуля Юнга) обученной КИНС с архитектурой «100–20–1» (табл. 6, строка № 1). Кружками изображены

Инженерное дело, технологии и технические науки

данные для тестирования E , треугольниками и квадратиками изображены прогнозируемые данные E_c , полученные с помощью КИНС. Относительные ошибки δ_E , δ_Q вычислялись по формуле $\delta_E = |E_c - E|/E$, $\delta_Q = |Q_c - Q|/Q$.

Таблица 2

Результаты обучения и тестирования КИНС со 2-й точкой позиционного измерения

№	Количество данных	Архитектура КИНС	Эпохи	Ошибка	Точность	Примечание	Количество точек на АЧХ
1	200	2–4–1	2000	0,073	84,80 %	В точке 2	1
2	200	6–3–1	2000	0,066	89,55 %	В точке 2	3
3	200	100–10–1	2000	0,017	96,29 %	В точке 2	50

Таблица 3

Результаты обучения и тестирования КИНС в различных точках (с одинаковым количеством эпох)

№	Количество данных	Архитектура КИНС	Эпохи	Ошибка	Точность	Примечание
1	200	100–10–1	2000	0,017	96,29 %	В точке 2
2	200	100–10–1	2000	0,018	92,86 %	В точке 4
3	200	100–10–1	2000	0,021	93,78 %	В точке 5

Таблица 4

Результаты обучения и тестирования КИНС с различным количеством данных обучения

№	Количество данных	Архитектура КИНС	Эпохи	Ошибка	Точность	Примечание
1	200	100–10–1	2000	0,017	96,29 %	В точке 2
2	300	100–10–1	2000	0,0057	97,64 %	В точке 2
3	500	100–10–1	2000	0,0053	98,37 %	В точке 2

Таблица 5

Результаты обучения и тестирования нейронных сетей с различным количеством скрытых слоёв при позиционном измерении во 2-й точке

№	Количество данных	Архитектура КИНС	Эпохи	Ошибка	Точность	Примечание	Время, с
1	500	100–5–1	2000	0,0121	98,13 %	В точке 2	96
2	500	100–10–1	2000	0,0053	98,37 %	В точке 2	219
3	500	100–20–1	2000	0,0019	99,09 %	В точке 2	300
4	500	100–50–1	2000	0,0067	97,71 %	В точке 2	834

Таблица 6

Результаты обучения и тестирования нейронной сети с различным количеством эпох при позиционном измерении во 2-й точке

№	Количество данных	Архитектура КИНС	Эпохи	Ошибка	Точность	Примечание	Время (Секунд)
1	500	100–20–1	2000	0,0019	99,09 %	В точке 2	300
2	500	100–20–1	5000	0,0012	98,18 %	В точке 2	784

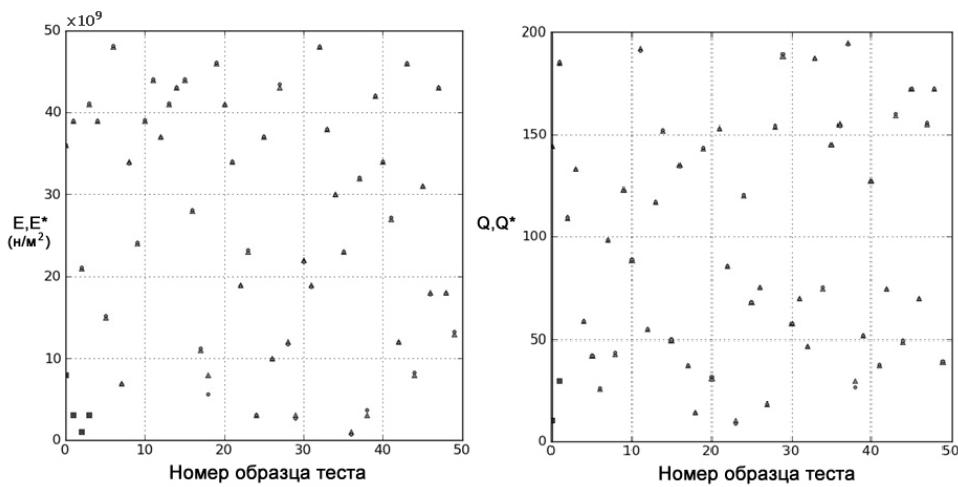


Рис. 4. Результаты тестирования (E, Q) при пороге ошибки 10 %

На рис. 5 представлены результаты тестирования на 50 примерах (рис. 5, а) (идентификации модуля Юнга и добротности) обученной КИНС с архитектурой «10–20–1» (табл. 6, строка № 1) и зависимость относительной ошибки (б) от числа эпох (рис. 5, б).

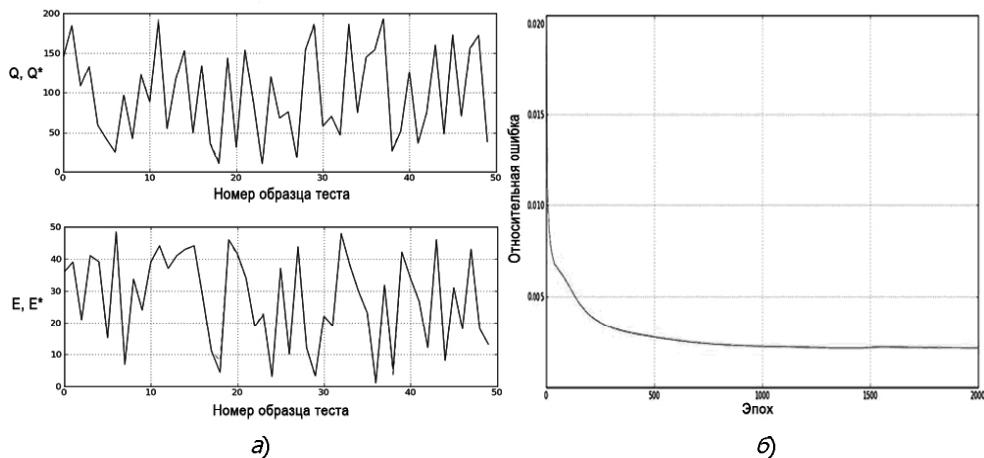


Рис. 5. Результаты тестирования обученной КИНС с архитектурой «10–20–1»:
а) результаты прогнозирования, полученные в системе; б) график ошибки обучения

Выводы. В результате проведённого исследования разработан метод идентификации упругих и диссипативных свойств твёрдого деформируемого тела, использующего данные гармонических колебаний на резонансной частоте на основе сочетания метода конечных элементов и КИНС. Осуществлена программная реализация метода и проведено его тестирование при использовании первой резонансной частоты колебаний. В результате численного эксперимента выявлены архитектуры КИНС, дающие лучший результат идентификации, а именно: 100 (входных нейронов) — 20 (скрытых нейронов) — 1 (выходной нейрон).

Проведена оценка временных затрат, связанных с обучением КИНС. Разработанный метод и программы могут быть использованы для определения диссипативных свойств на различных частотах (не только первой), а также для более сложных свойств упругого тела, например при наличии анизотропии.

Библиографический список

1. Haykin, S. Neural Network: a comprehensive foundation / S. Haykin. — 2nd edition. — [S. l.] : Prentice Hall, 1998. — 842 p.

2. Идентификация трещиноподобных дефектов в упругих элементах конструкций на основе эволюционных алгоритмов / А. А. Краснощёков [и др.] // Дефектоскопия. — 2011. — № 6. — С. 67–78.
3. Liu, S. W. Detection of cracks using neural networks and computational mechanics / S. W. Liu [et al.] // Computer methods in applied mechanics and engineering. — 2002. — Vol. 191. — Pp. 2831–2845.
4. Hasan, T. An application of neural networks for harmonic coefficients and relative phase shifts detection / T. Hasan, T. Feyzullah // Expert Systems with Applications. — 2011. — Vol. 38, iss. 4. — Pp. 3446–3450.
5. Khandetsky, V. Signal processing in defect detection using back-propagation neural networks / V. Khandetsky, I. Antonyuk // NDT&E International. — 2002. — Pp. 483–488.
6. Adaptive multilayer perceptron networks for detection of cracks in anisotropic laminated plates / Y. G. Xu [et al.] // International journal of solids and structures. — 2001. — Vol. 38. — Pp. 5625–5645.
7. Korczak, P. Using neural network models for predicting mechanical properties after hot plate rolling processes / P. Korczak, H. Dyja, E. Łabuda // Journal of Materials Processing Technology. — 1998. — Vol. 80–81. — Pp. 481–486.
8. Mira, T. Predicting mechanical properties of elastomers with neural networks / T. Mira, S. Zoran, L. Uros // Polymer. — 2007. — Vol. 48. — Pp. 5340–5347.
9. Ghaisari, J. Artificial neural network predictors for mechanical properties of cold rolling products / J. Ghaisari, H. Jannesari, M. Vatani // Advances in Engineering Software. — 2012. — Vol. 45. — Pp. 91–99.
10. Iztok, P. Determination of scrap/supply probability curves for the mechanical properties of aluminium alloys in hot extrusion using a neural network-like approach / P. Iztok, T. Milan, K. Goran // Expert Systems with Applications. — 2012. — Vol. 39. — Pp. 5634–5640.
11. Determination of the influence of processing parameters on the mechanical properties of the Ti-6Al-4V alloy using an artificial neural network / Y. Sun [et al.] // Computational Materials Science. — 2012. — Vol. 60. — Pp. 239–244.
12. Nitta, T. A back-propagation algorithm for complex numbered neural networks / T. Nitta // Proceedings International Joint Conference on Neural Networks, IEEE, Nagoya. — 1993. — Pp. 1649–1652.
13. Nitta, T. An extension of the back-propagation algorithm to complex numbers / T. Nitta // Neural Network. — 1997. — Vol. 10. — Pp. 1391–1415.
14. Hirose, A. Complex-valued neural networks: Theories and applications / A. Hirose, E. River // The Series on innovative intelligence. — 2003. — 388 p.
15. Li, C. Complex-valued wavelet network / C. Li, X. Liao, J. Yu // Journal of Computer and System Sciences. — 2003. — Vol. 67. — Pp. 623–632.
16. Nitta, T. Complex-valued neural networks: utilizing high-dimensional parameters / T. Nitta // Information Science Reference. — 2009. — 504 p.
17. Белоконь, А. В. Новые схемы конечно-элементного динамического анализа пьезоэлектрических устройств / А. В. Белоконь, А. В. Наседкин, А. Н. Соловьев // Прикладная математика и механика. — 2002. — Т. 66, № 3. — С. 491–501.
18. Новацкий, В. Теория упругости / В. Новацкий. — Москва : Мир, 1976. — 872 с.

Материалы поступили в редакцию 08.11.2013.

References

1. Haykin, S. Neural Network a comprehensive foundation (2nd edition). Prentice Hall. 1998, 842 p.
2. Krasnoshchekov, A. A., Sobol, B. V., Solovyev, A. N., Cherpakov, A. V. Identifikatsiya treshchinopodobnykh defektov v uprugikh elementakh konstruktsiy na osnove evolyutsionnykh algoritmov. [Identification of crack-like defects in elastic structural elements based on evolutionary algorithms.] Defektoskopiya, 2011, no. 6, pp. 67–78 (in Russian).
3. Liu, S. W., Huang, J. H., Sung, J. C., Lee, C. C. Detection of cracks using neural networks and computational mechanics. Computer methods in applied mechanics and engineering, 2002, vol. 191, pp. 2831–2845.
4. Hasan, T., Feyzullah, T. An application of neural networks for harmonic coefficients and relative phase shifts detection. Expert Systems with Applications, 2011, vol. 38, iss. 4, pp. 3446–3450.
5. Khandetsky, V., Antonyuk, I. Signal processing in defect detection using back-propagation neural networks. NDT&E International, 2002, pp. 483–488.
6. Xu, Y. G., Liu, G. R., Wu, Z. P., Huang, X. M. Adaptive multilayer perceptron networks for detection of cracks in anisotropic laminated plates. International journal of solids and structures, 2001, vol. 38, pp. 5625–5645.
7. Korczak, P., Dyja, H., Łabuda, E. Using neural network models for predicting mechanical properties after hot plate rolling processes. Journal of Materials Processing Technology, 1998, vol. 80–81, pp. 481–486.
8. Mira, T., Zoran, S., Uros, L. Predicting mechanical properties of elastomers with neural networks. Polymer, 2007, vol. 48, pp. 5340–5347.
9. Ghaisari, J., Jannesari, H., Vatani, M. Artificial neural network predictors for mechanical properties of cold rolling products. Advances in Engineering Software, 2012, vol. 45, pp. 91–99.
10. Iztok, P., Milan, T., Goran, K. Determination of scrap/supply probability curves for the mechanical properties of aluminium alloys in hot extrusion using a neural network-like approach. Expert Systems with Applications, 2012, vol. 39, pp. 5634–5640.
11. Sun, Y., Zeng, W., Han, Y., Ma, X., Zhao, Y., Guo, P., Wang, G. Determination of the influence of processing parameters on the mechanical properties of the Ti-6Al-4V alloy using an artificial neural network. Computational Materials Science, 2012, vol. 60, pp. 239–244.
12. Nitta, T. A back-propagation algorithm for complex numbered neural networks. Proceedings International Joint Conference on Neural Networks, IEEE, Nagoya. 1993, pp. 1649–1652.
13. Nitta, T. An extension of the back-propagation algorithm to complex numbers. Neural Network, 1997, vol. 10, pp. 1391–1415.
14. Hirose, A., River, E. Complex-valued neural networks: Theories and applications. The Series on innovative intelligence. 2003, 388 p.
15. Li, C., Liao, X., Yu, J. Complex-valued wavelet network. Journal of Computer and System Sciences, 2003, vol. 67, pp. 623–632.
16. Nitta, T. Complex-valued neural networks: utilizing high-dimensional parameters. Information Science Reference. 2009, 504 p.
17. Belokon, A. V., Nasedkin, A. V., Solovyev, A. N. Novyye skhemy konechno-elementnogo dinamicheskogo analiza pyezoelektricheskikh ustroystv. [New schemes of finite element dynamic analysis of piezoelectric devices.] PMM, 2002, vol. 66, no. 3, pp. 491–501 (in Russian).
18. Novatskiy, V. Teoriya uprugosti. [Elasticity theory.] Moscow: Mir, 1976, 872 p. (in Russian).

ELASTIC AND DISSIPATIVE MATERIAL PROPERTIES DETERMINATION USING COMBINATION OF FEM AND COMPLEX ARTIFICIAL NEURAL NETWORKS*

A. N. Solovyev, Nguyen Duy Truong Giang

The application of the complex artificial neural networks (CANN) to the inverse identification problem of the elastic and dissipative properties of deformable solids is considered. The additional information to the inverse problem is components of the displacement vector measured in a set of points at the solid boundary (positional measurement). This solid performs harmonic oscillations in the first resonant frequency. The process of displacement measurement is simulated using the calculation of finite elements software ANSYS, the building of the amplitude-frequency characteristics (AFC) of the displacement, and of the selection of their values for a set of frequencies (frequency measurement). In the given numerical example, problems on the accurate identification of the elastic modulus, and material quality depending on the number of measure points and their location, as well as on the neural network architecture and the length of the training process performed by the complex-value error back propagation (CBP) algorithm are investigated.

Keywords: complex-valued artificial neural networks, identification of mechanical properties, finite element method.

* The research is done with the partial financial support from RFFI (grants nos. 13-01-00196-a, 13-01-00943-a).