

## Нейросетевой подход к диагностике несквозных трещин в тонких пластинах

*Н.И. ОБОДАН, В.Я. АДЛУЦКИЙ, Э.М. КИСЕЛЕВ*

Днепропетровский национальный университет

Розроблено і чисельно реалізовано алгоритм діагностики ненаскрізних тріщин у тонких платівках за результатами непрямих вимірів з використанням нейронних мереж. За вимірювані параметри вибираються нормальні переміщення в дискретних точках поверхні платівки, що доступні для безпосереднього моніторингу. Пряма задача про напружено-деформований стан платівки, що містить ненаскрізну тріщину, розв'язується за допомогою МСЕ. Навчання багатослойних нейронних мереж на основі перцептрона здійснюється з використанням методу зворотного розповсюдження помилки.

Разработан и численно реализован алгоритм диагностики несквозных трещин в тонких пластинках по результатам косвенных измерений с использованием нейронных сетей. За измеренные параметры выбираются нормальные перемещения в дискретных точках поверхности пластины, которые доступны для непосредственного мониторинга. Прямая задача о напряженно-деформированном состоянии пластины, которая содержит несквозную трещину, решается с помощью МСЕ. Обучения многослойных нейронных сетей на основе перцептрона осуществляется с использованием метода обратного распространения ошибки.

The algorithm of diagnostics of non-through cracks in thin plates based on results of indirect measurements with use of neural networks is developed and numerically realized. The normal displacements at discrete points of the plate surface are chosen as measured parameters. The direct problem about stress-strain state of the thin plate containing non-through crack is solved by FEM. The learning of multi-layer neural networks based on the perceptron is accomplished through the use of error back-propagation method.

**Современное состояние вопроса.** Вопросы диагностики повреждений в тонкостенных конструкциях являются весьма актуальными с точки зрения обеспечения надлежащей надежности и живучести изделий, содержащих такие элементы. Очевидно, что основой успешной реализации алгоритмов диагностики является наличие решения прямой задачи о повреждении. Исследованию тонкостенных конструкций, ослабленных сквозными трещинами и отверстиями, посвящено весьма большое количество публикаций, в которых теоретически и экспериментально установлены особенности напряженно-деформированного состояния и изучено влияние геометрических и физических параметров. Более сложной с точки зрения построения математических моделей является проблема несквозных трещин. Наличие последних обуславливает преобладание изгибных факторов в процессе деформирования даже для изначально плоских конструкций.

В последнее время все более увеличивается число публикаций, посвященных использованию физических косвенных методов неразрушающего контроля повреждений в материале: ультразвуковое, акустическое, магнитное воздействие и т. п. Интенсивно развиваются математические методы решения некорректных задач для идентификации повреждений [1, 2].

Развитие метода неразрушающего контроля с использованием методов искусственного интеллекта, и, в частности, нейронных сетей, находится на начальной стадии. Появились публикации, относящиеся к сфере металлургии и машиностроения, однако все опубликованные методы базируются на простейших моделях или используют статистические данные, как правило, весьма противоречивые с точки зрения причин разрушения. Следует отметить, что решение методом нейросетевого управления обратных задач вообще, а тем более – для деформируемых тел, для которых эти задачи плохо обусловлены, представляет большие трудности. В литературе до сих пор практически отсутствуют сведения об

использовании нейронных сетей в сочетании с моделями механики сплошных сред.

Целью данной статьи является построение и реализация алгоритма диагностики параметров несквозных трещин в тонких пластинах по результатам измерений перемещений в дискретных точках лицевой поверхности с использованием многослойных нейронных сетей на основе перцептрона.

В данной статье прямая задача о напряженно-деформированном состоянии тонкой пластины, содержащей несквозную трещину, решается с помощью МКЭ. Из нормальных перемещений, измеренных на множестве точек съема информации, расположенных на лицевой поверхности пластины, формируется вектор входных параметров для нейронной сети, предназначенной для обучения. Для локализации трещины поперечное сечение пластины разбивается на ряд зон, и в качестве выходных параметров для нейронной сети выступают номера зон, в которых находятся трещины.

**Постановка задачи.** Рассматривается тонкая прямоугольная пластина (рис.1) длиной  $2b$ , шириной  $a$  и толщиной  $h$ , центральное сечение которой ( $z=0$ ) ослаблено несквозной трещиной прямоугольной формы длиной  $l$  и глубиной  $h_1$ . Трещина расположена на расстоянии  $d$  от боковой поверхности. Пластина жестко закреплена по торцам и растянута на незначительную величину  $\delta$  так, чтобы в ней не возникли остаточные напряжения. Наличие трещины обуславливает изгиб пластины, который фиксируется индикаторами в дискретных точках поверхности, на которую выходит трещина (рис.2). Задача состоит в том, чтобы по дискретным значениям измеренных прогибов определить глубину и положение несквозной трещины в центральном сечении пластины.

**Метод решения.** Для решения поставленной задачи применяется метод многослойных нейронных сетей (МНС). Для обучения МНС используются решения

прямой задачи механики деформируемого тела для пластины с несквозной трещиной в центральном сечении, расположение и размеры которой варьируются.

Решение прямой задачи строится на основе МКЭ путем разбиения пластины на трехмерные восьмиузловые изопараметрические конечные элементы  $\Omega_i, i = \overline{1, Q}$  с узлами  $D_k, k = \overline{1, T}$ , где  $Q$  – общее число конечных элементов,  $T$  – общее число узлов конечноэлементной сетки. С целью локализации трещины вводится разбиение центрального сечения пластины  $z=0$  на зоны  $S_j, j = \overline{1, P}$  возможного расположения трещины.




Рис. 1

Информация о нормальных перемещениях пластины с несквозной трещиной  $g$  формируется в точках съема информации  $M_i, i = \overline{1, N}$ , ( $N \ll T$ ), равномерно распределенных по лицевой поверхности пластины в ее центральном сечении.




Рис. 2

Для каждой трещины вектор перемещений в точках съема информации  $W^* = \{w(M_1), \dots, w(M_N)\}$  (где  $w(M_i)$  – нормальное перемещение в точке  $M_i$  в глобальной декартовой системе координат) представляет собой совокупность входных параметров МНС. В качестве вектора выходных параметров служит вектор  $H$ , определяющий зону локализации трещины,  $H = \{h_1, \dots, h_P\}$ , где

$$h_i = \begin{cases} 1, & g \in S_i \\ 0, & g \notin S_i \end{cases}, \quad i = \overline{1, P}.$$

Обучающая последовательность  $B = \{b^{(1)}, \dots, b^{(r)}\}$ ,

$b^{(i)} = \{W^{*(i)}, H^{(i)}\}$ ,  $i = \overline{1, r}$  состоит из  $r$  образцов.

Используется полносвязная МНС на основе персептрона, в которой каждый базовый элемент  $l$ -го слоя ( $l = \overline{0, K-1}$ ) передает свой входной сигнал с определенными весовыми коэффициентами всем нейронам следующего  $(l+1)$ -го слоя. Связи между базовыми элементами в слое отсутствуют. Обозначим  $n_0$  – число базовых элементов во входном слое,  $n_l, l = \overline{1, K-1}$  – число базовых элементов в  $l$ -м скрытом слое,  $n_K$  – число базовых элементов в выходном слое. С учетом структуры входного и выходного векторов очевидно, что  $n_0 = 3N, n_K = P$ . Выходной сигнал  $i$ -го базового элемента в  $l$ -м слое МНС вычисляется в виде

$$q_i^{(l)} = f\left(\sum_{j=1}^{n_{l-1}} \alpha_{ij}^{(l)} \cdot q_j^{(l-1)} + \alpha_{i0}^{(l)} \cdot q_0^{(l-1)}\right) = f(s_j^{(i)}),$$

или в векторной форме

$$\bar{q}^{(l)} = \mathbf{f}(\mathbf{A}^{(l)} \bar{q}^{(l-1)} + \alpha_0^{(l)} \bar{q}_0^{(l-1)}) = \mathbf{f}(\bar{q}^{(l-1)}),$$

$$\bar{\mathbf{q}}^{(l)} = \text{col}(q_1^{(l)}, \dots, q_{n_l}^{(l)}),$$

$$\bar{\mathbf{q}}^{(l-1)} = \text{col}(q_1^{(l-1)}, \dots, q_{n_{l-1}}^{(l-1)}),$$

$$s_i^{(l)} = \sum_{j=0}^{n_{l-1}} \alpha_{ij}^{(l)} q_j^{(l-1)} = (\bar{\alpha}_i^{(l)})^T \bar{\mathbf{q}}^{(l-1)},$$

где  $\alpha_{ij}^{(l)}$  – весовой коэффициент связи, идущей от базового элемента с номером  $j$  к базовому элементу с номером  $i$ ;  $q_i^{(l)}$  – активность  $i$ -го элемента в слое  $l$ ;  $\alpha_{i0}^{(l)}$  – весовой коэффициент, связанный с элементом смещения в  $(l-1)$ -м слое, значение активности которого  $q_0^{(l-1)} = +1$  для всех  $l = \overline{2, K}$ ;  $f(x)$  – функция активации, которая в данном исследовании принята в виде гиперболического тангенса

$$f(x) = \tanh(x) = \frac{\exp(x) - \exp(-x)}{\exp(x) + \exp(-x)}.$$

С использованием введенных обозначений среднеквадратичная ошибка наблюдаемого сигнала в выходном слое для  $s$ -го образца равна

$$E_s = \frac{1}{2} \sum_{i=1}^P (q_i^{(K)} - h_i)^2,$$

а общая ошибка для всей последовательности образцов  $B$  –

$$E = \sum_{s=1}^r E_s.$$

Для управляемого обучения МНС, в процессе которого веса  $\alpha_{ij}^{(l)}$  корректируются с целью минимизации ошибки  $E$ , применяется алгоритм обратного распространения ошибок (backpropagation) [3–8], использующий два потока в сети: прямой поток от входного слоя к выходному и обратный – от выходного слоя к входному. В то время, как прямой поток продвигает входные векторы через сеть, в результате чего в выходном слое получаются выходные значения сети, обратный поток продвигает назад по сети значения ошибок, в результате чего определяются величины, в соответствии с которыми корректируются веса в процессе обучения.

Минимизация ошибки осуществляется методом градиентного спуска, в соответствии с которым весовые коэффициенты получают следующие приращения

$$\Delta\alpha_{ij} = -\eta \frac{\partial E}{\partial \alpha_{ij}},$$

где  $\eta$  – норма обучения.

В соответствии с методом обратного распространения ошибки

$$\bar{\alpha}_i^{(K)}(n+1) = \bar{\alpha}_i^{(K)}(n) + \eta f'(s_i^{(K)}(n+1)) e_{w_i}(n+1) \bar{q}^{(K-1)}(n+1) =$$

$$= \bar{\alpha}_i^{(K)}(n) + \eta \sigma_i^{(K)}(n+1) \bar{q}^{(K-1)}(n+1),$$

$$e_{w_i}(n+1) = w_i^* - w_i(\bar{H}(n+1)),$$

$$\bar{q}^{(K-1)} = \text{col}(q_0^{(K-1)}, q_1^{(K-1)}, \dots, q_{n_{K-1}}^{(K-1)}),$$

где  $n$  – номер итерации (эпохи).

Скалярная обобщенная погрешность обучения нейросети для  $i$ -го базового элемента в слое  $K-1$  имеет вид

$$\begin{aligned} A^{(K-1)}(n) &= -A^{(K)}(n) \bar{e}_w(n), \\ (f'(s^{(K-1)}(n+1)))^T A^{(K-1)}(n) &= \\ &= -(f'(s^{(K-1)}(n+1)))^T A^{(K)}(n) \bar{e}_w(n) = \sigma_i^{(K-1)}(n+1), \\ \bar{e}_w(n) &= \bar{W}^* - \bar{W}(\bar{H}(n)). \end{aligned}$$

С ее использованием получаем алгоритм настройки, по форме в точности соответствующий  $\delta$ -правилу

$$\bar{\alpha}_i^{(K-1)}(n+1) = \bar{\alpha}_i^{(K-1)}(n) - \eta \sigma_i^{(K-1)}(n) \bar{q}^{(K-2)}(n+1),$$

$$\bar{\sigma}_i^{(K-1)}(n+1) = -(f'(s^{(K-1)}(n+1)))^T A^{(K)}(n) \bar{e}_w(n),$$

Начальные значения весовых коэффициентов МНС формируются случайным образом. Для устранения осцилляции и ускорения сходимости итерационного процесса модификации весовых коэффициентов используется следующее соотношение:

$$\Delta\alpha_{ij}(n+1) = -\eta \frac{\partial E}{\partial \alpha_{ij}} + \rho \Delta\alpha_{ij}(n),$$

где  $\rho$  – коэффициент инерции.

С целью недопущения «перетренировки» МНС, при которой сеть слишком хорошо повторяет учебные данные и не позволяет новым экземплярам достаточно далеко отклоняться от них, процесс обучения сочетается с периодическим пропуском через сеть набора тестовых данных. Обучение продолжается до тех пор, пока общая ошибка тестовых данных уменьшается, и прекращается, как только она начинает расти. Естественно, тестовые данные не предъявляются сети в качестве учебных.

**Анализ результатов.** Численные эксперименты осуществлялись с помощью пакета программ, реализующих конечноэлементное решение прямых задач, генерацию обучающих и тестовых наборов данных, рандомизацию порядка их компонентов, построение, обучение и тестирование МНС. Строились МНС с различным количеством скрытых слоев и базовых элементов в этих слоях.

Рассматривались пластины со следующими значениями геометрических параметров:  $a=70$  мм,  $b=175$  мм,  $h=0,23$  мм. При этом геометрические параметры трещин изменялись в следующих пределах:

$$0,125 \leq \frac{h_1}{h} \leq 0,875; \quad 0 \leq \frac{d}{a} \leq 0,8; \quad 0,2 \leq \frac{l}{a} \leq 0,5.$$




Рис. 3

Типичный характер напряженно-деформированного состояния пластины с несквозной трещиной  $g$  при  $d=0,1a$ ;  $l=0,12a$ ;  $h_1 = 0,2h$ ;  $\delta = 0,0006b$  приведен на рис.3, где линиями уровня обозначены эквивалентные напряжения (представленные в  $\text{кг/мм}^2$ ) в окрестности трещины. В данном случае пластина с несквозной трещиной моделируется с использованием сетки из 15000 конечных элементов со сгущением их к центральному сечению. По толщине пластины располагается 8 слоев конечных элементов.

В рассматриваемом случае максимальное нормальное перемещение пластины достигается в центре трещины и составляет 0,0026 мм. Выпучивание пластины происходит в сторону поверхности, на которую выходит трещина. Для любого другого расположения трещины напряженно-деформированное состояние пластины в ее окрестности остается качественно подобным приведенному на рис. 3.

Обучение МНС производилось методом обратного распространения ошибок с использованием обучающих наборов данных, содержащих от  $r=144$  до  $r=180$  образцов, упорядоченных случайным образом. Каждый образец являлся результатом решения прямой задачи для пластины с несквозной трещиной определенной длины и глубины, расположенной в одной из зон локализации  $S_j$ . Число зон локализации  $P$  варьировалось от 4 до 8, а число точек съема информации  $N$  – от 11 до 22. В качестве тестовых данных, используемых в процессе обучения, формировалась десятипроцентная выборка из обучающего набора. На этапе тестирования настроенной МНС использовались двадцатипроцентные выборки из обучающих наборов данных, не предъявлявшиеся в процессе обучения.

Способность к обобщению построенных МНС существенно зависела от числа и расположения точек съема информации. Например, использование точек съема информации, расположенных вне окрестности трещины, не позволяло произвести настройку МНС с достаточной для практики точностью, что связано с локальным характером выпучивания пластины, и, как следствие, плохой обусловленностью исходной задачи и малой репрезентативностью наборов точек съема информации, удаленных от трещины. Наиболее эффективным оказалось расположение точек съема информа-

ции на лицевой поверхности пластины в ее центральном сечении (рис. 2).

Результаты расчетов с варьированием количества скрытых слоев МНС показали, что сети с большим количеством скрытых слоев обладают более высокой способностью к обобщению, однако чрезмерное увеличение их числа (более 4), существенно замедляет процесс обучения из-за большого объема вычислений. Существенное влияние на обучение МНС оказывало количество зон локализации трещины: например, рассмотрение четырех зон:

$$1) 0 < \frac{d}{a} < 0,5; 0 < \frac{h_1}{h} < 0,5;$$

$$2) 0,5 < \frac{d}{a} < 1,0; 0 < \frac{h_1}{h} < 0,5;$$

$$3) 0 < \frac{d}{a} < 0,5; 0,5 < \frac{h_1}{h} < 1,0;$$

$$4) 0,5 < \frac{d}{a} < 1,0; 0,5 < \frac{h_1}{h} < 1,0;$$

позволяло настроить МНС на 100%-е получение правильных тестовых решений, тогда как увеличение числа зон уменьшало число правильных результатов при тестировании до 85-90%. Попытки идентификации значений параметров трещин, а не зон их расположения, оказывались unsuccessful, поскольку на стадии обучения не удавалось достичь приемлемого уровня погрешности итерационного процесса минимизации ошибки обучения. Вследствие этого, на этапе тестирования наиболее точно идентифицируемыми параметрами являлись глубина трещины и ее положение относительно оси симметрии поперечного сечения, тогда как длина трещины идентифицировалась намного хуже.

В целом, решение рассматриваемой задачи оказалась намного более трудоемким, чем, например, задачи об идентификации сквозных отверстий-повреждений в тонких цилиндрических оболочках [9]. Если в последнем случае обучение МНС осуществлялось за несколько тысяч эпох, то для рассматриваемой задачи оно требовало нескольких сотен тысяч эпох. Причиной этого является особенность рассматриваемого типа повреждений, связанная с их локализацией в поперечном сечении достаточно тонкой пластины, что делает входные данные слабо отличающимися друг от друга. Описанный выше метод минимизации ошибки в чистом виде оказался недостаточно эффективным, поскольку соот-

ветствующий итерационный процесс имел неустойчивый и к тому же весьма осциллирующий характер. Альтернативой являлось использование на определенных этапах итерационного процесса метода сопряженных градиентов, который обеспечивал монотонный характер сходимости.

### Выводы

Таким образом, численная реализация предложенного подхода экспериментально подтвердила способность МНС служить средством определения наличия несквозных трещин в тонких пластинах и локализации их с достаточной для практических целей точностью. В силу специфики рассматриваемого типа повреждений, решение подобных задач оказалось намного более трудоемким, чем, например, задач об идентификации сквозных отверстий в тонкостенных элементах конструкций.

### ЛИТЕРАТУРА

1. Ободан Н.И., Богачев А.С., Шульга А.С. Диагностика механических систем по косвенным измерениям с помощью нейронной сети // Theor. Found. of Civil Eng. XII. – Warsaw, 2004. – P.783-788.
2. Головкин В.А. Нейроинтеллект: Теория и применение. – Брест: БПИ, 1999. – 234 с.
3. Калан Р. Основные концепции нейронных сетей. – М.: Изд. Дом «Вильямс», 2001. – 288 с.
4. Терехов В.А., Ефимов Д.В., Тюкин И.Ю. Нейросетевые системы управления. – М.: ИПРЖР, 2002. – 480 с.
5. Werbos P.J. Backpropagation through time: what it does and how to do it // Proc. of the IEEE, 78(10), 1990. – P. 1550-1560.
6. Kröse B., van der Smagt P. An introduction to neural networks, 8-th ed. – The Univ. of Amsterdam, 1996. – 140 p.
7. Werbos P.J. Backpropagation through time: what it does and how to do it // Proc. of the IEEE, 78(10), 1990. – P. 1550-1560.
8. Хайкин С. Нейронные сети. Полный курс. – М.: Изд. Дом «Вильямс», 2006. – 1104 с.
9. Ободан Н.И., Адлуцкий В.Я., Киселев Э.М. Локализация повреждений в тонких оболочках на основе нейросетевого подхода. – (В печати).