

*Короткая Л.И.*

## АЛГОРИТМ ПОЛУЧЕНИЯ УЧЕБНЫХ ОБРАЗЦОВ ДЛЯ НЕЙРОННОЙ СЕТИ ПРИ РЕШЕНИИ ЗАДАЧ ДОЛГОВЕЧНОСТИ КОРРОДИРУЮЩИХ КОНСТРУКЦИЙ

ГВУЗ «Украинский государственный химико-технологический университет», г. Днепр

При решении задач прогнозирования долговечности корродирующих конструкций предлагается использовать технологии вычислительного интеллекта, в частности искусственные нейронные сети. Выделяют определённые необходимые этапы при их проектировании и работе с ними. Важным из них является способ получения качественной обучающей выборки. Дальнейшая настройка и применение нейронной сети напрямую зависит от свойств полученных учебных образцов. Задача прогнозирования долговечности является частью более общей задачи – задачи оптимального проектирования конструкций, которые функционируют в агрессивных внешних средах. Поэтому вычисление прогнозируемого значения долговечности (или вычисление функций ограничений в задаче оптимизации) предполагает многократное численное решение системы дифференциальных уравнений, которая описывает процесс накопления геометрических повреждений корродирующей конструкции. Определение рациональных параметров численного интегрирования в целом позволяет повысить эффективность вычислительного алгоритма. С целью получения рационального шага интегрирования системы дифференциальных уравнений с погрешностью, не превышающей заданную, предлагается использовать аппроксимирующую систему, которой является искусственная нейронная сеть. Определение входных параметров, от которых зависит погрешность полученного решения, позволяет определиться с архитектурой нейронной сети. В работе сделан анализ зависимостей параметров численного интегрирования и входных параметров в целом, на основании которого определён вектор входных параметров для нейронной сети. Предложен алгоритм получения элементов входного вектора. С целью исключения «пустых» зон в обучающей выборке предложено предварительное её разбиение на кластеры. Такой подход позволяет избежать получения некачественной выборки и не снижает эффективности всего вычислительного алгоритма. Предложенная методика получения учебных данных позволяет улучшить качество обучения нейронной сети.

**Ключевые слова:** искусственные нейронные сети, обучающая выборка, прогнозирование долговечности, корродирующие конструкции.

### *Постановка проблемы*

С целью повышения качества конструкторских решений, связанных с проектированием элементов оборудования предприятий химической, нефтеперерабатывающей, металлургической, горной промышленности и строительной индустрии необходимо наличие математических моделей объектов. В большинстве случаев эти объекты представляют собой сложные динамические системы, параметры которых изменяются во времени. Причины этих изменений могут вызываться различными факторами: во многих

случаях, влиянием технологических сред, процессами деградации материалов, изменяющимися во времени нагрузками.

В результате коррозии металла, вызванной воздействием внешних агрессивных сред, происходят изменения геометрических и прочностных характеристик элементов конструкций и, как следствие, преждевременный, а иногда и аварийный выход их из строя.

Анализ проблемных аспектов моделирования поведения корродирующих конструкций (КК) и прогнозирования их долговечности, по-

казал, что существующие методы и алгоритмы их реализации зачастую оказываются ненадёжными и малоэффективными при решении поставленных задач.

По мнению автора, многие проблемы, возникающие при моделировании рассматриваемых динамических систем, могут быть решены с использованием технологий вычислительного интеллекта.

#### ***Анализ последних исследований и публикаций***

Существующие подходы к исследованию и моделированию поведения механических систем, корродирующих конструкций в том числе, и их элементов при воздействии агрессивной внешней среды позволяют в рамках существующих моделей и методов спрогнозировать сроки их эксплуатации.

Как отмечалось в известных работах [1–4] шаг интегрирования при решении системы дифференциальных уравнений (СДУ), описывающей коррозионный процесс в элементах конструкции, являлся параметром решаемой задачи. Это не обеспечивало необходимой точности получаемого результата для одного подмножества пространства решений, а для другого его подмножества приводило к избыточным вычислительным затратам. Указанные ситуации негативно отражаются на точности и эффективности вычислительного алгоритма в целом.

Создание такого алгоритма, который на основе информации о геометрических характеристиках сечений элементов конструкции, начальных напряжений и скорости коррозии, должен сам выбрать значение шага интегрирования, которое обеспечит заданную точность вычислений, возможно с использованием нейросетевых моделей представления знаний [5,6]. Адаптируемые и обучаемые нейронные сети (НС) представляют собой распараллеленные системы, которые способны к обучению путём анализа как положительных, так и отрицательных воздействий.

#### ***Формулирование цели исследования***

Очевидно, возникает необходимость в некотором управляющем модуле, позволяющем получать такие параметры численного интегрирования, при которых погрешность  $\varepsilon$  получаемого решения СДУ не превышала бы предельно допустимых значений  $[\varepsilon]$ .

Такой рациональный выбор параметров численных процедур (а именно, шага интегрирования  $h_t$ ), позволил бы обеспечить точность решения с одной стороны, а с другой – избежать излишнего количества итераций. Выбор

рационального шага интегрирования при решении СДУ, описывающей процесс накопления геометрических повреждений КК, будет означать то, что при решении задачи Коши не будет избыточного количества итераций, что очень существенно для повышения эффективности вычислительного алгоритма.

Для успешного решения проблемы обеспечения точности вычисления функций ограничений при решении задачи оптимального проектирования КК (частью которой и является задача прогнозирования долговечности), следует получить зависимость между  $h_t$  и векторами  $\bar{c}$ ,  $\varepsilon$ .

Для построения аппроксимирующей функции необходимо выполнить этапы:

- получить множество эталонных решений;
- на основании анализа эталонных решений определить входные параметры функции аппроксимации;
- выбрать способ аппроксимации.

Постановку задачи управления точностью численного результата при заданной погрешности можно сформулировать в следующем виде:

$$\begin{cases} h_t(\varepsilon, \bar{c}) \rightarrow \max; \\ \varepsilon(\bar{c}, h_t) \leq [\varepsilon]. \end{cases} \quad (1)$$

Здесь  $\bar{c}$  – вектор факторов, влияющих на величину шага интегрирования.

#### ***Изложение основного материала исследований***

Погрешность численного решения задачи долговечности будет зависеть [2,6] от следующих факторов: начальных геометрических характеристиках элемента (площади  $A_0$  и периметра  $P_0$ ), начального  $\sigma_0$  и предельного  $[\sigma]$  напряжений в нём, параметров коррозионного процесса и предельно допустимого значения погрешности  $[\varepsilon]$ . Следовательно, погрешность численного решения дифференциального уравнения, описывающего коррозионный износ, можно представить как функцию нескольких переменных:  $\varepsilon(v_0, A_0, P_0, \sigma_0, [\sigma], h_t)$ . В работе предлагается алгоритм управления точностью решения СДУ, как отмечалось ранее, с использованием технологий вычислительного интеллекта, в частности, искусственных нейронных сетей (ИНС) [6].

Сформулированная задача (1) является задачей аппроксимации, поэтому в работе предлагается применение многослойного перцептрона в качестве универсального аппроксиматора. Как известно, для дальнейшего успешного ис-

пользования ИНС, необходимы учебные и тестовые образцы для настройки сети. Далее предлагается методика получения обучающей выборки (ОВ).

Успех применения нейронной сети обычно требует проведения значительного числа экспериментов. Несомненно, важным фактором является выбор учебных данных. Множество образцов должно обладать наибольшей информационной насыщенностью и минимальной зашумлённостью.

Ввиду того, что задача прогнозирования долговечности КК решалась неоднократно, то такая информация об указанной зависимости имеется, но носит рассеянный характер. В работе [6] эти знания формализует нейронная сеть, которая будет для каждого конкретного случая находить значение параметра численных процедур и обеспечивать заданную точность вычислений.

В [6] предложена и обоснована возможность получения обучающих образцов не для конструкции в целом, а для её отдельных элементов. Это позволяет с одной стороны упростить решение задачи долговечности для учебного образца, а с другой – создать достаточно универсальную нейронную сеть для расчёта шарнирно-стержневых конструкций с произвольной геометрией, граничными условиями и условиями нагружения.

Обычно предельно допустимая погрешность решения задачи задаётся не как непрерывная величина, а в виде ряда пороговых значений, например,  $[\varepsilon] \leq 3\%; 6\%; 10\%$ . Поэтому для упрощения архитектуры сети и, соответственно, уменьшения обучающей выборки в данной работе предлагается обучать нейронную сеть для конкретного порогового значения погрешности. Это несколько не сокращает пределы применимости нейросетевого подхода к управлению точностью решения СДУ, поскольку отдельная нейронная сеть может быть обучена для каждого порогового значения предельно допустимой погрешности.

Методика получения обучающей выборки представлена следующей последовательностью действий.

*1 шаг.* На данном этапе получения выборки обучающих образцов происходит генерация входящих параметров решения задачи  $\bar{c} = [A_0, P_0, \sigma_0, [\sigma], v_0]$ , равномерно распределённых на некотором интервале изменения этих параметров:

$$c_i = c_i^- + \alpha_i (c_i^+ - c_i^-); \quad \alpha_i \in (0; 1). \quad (2)$$

В том случае, если элемент конструкции представляет собой стержень при одноосном растяжении то, как показано в [2], для определения его долговечности достаточно знать начальный периметр  $P_0$  и площадь сечения  $A_0$ . Форма сечения в данном случае не влияет на результат решения и для удобства любой профиль можно рассчитывать как стержень трубчатого сечения с площадью и периметром, соответствующим площади и периметру исходного стержня.

*2 шаг.* Этап предполагает получение эталонного решения задачи долговечности  $t_{\text{э}}^*$  для сгенерированных параметров конструкции и агрессивной среды. Эталонное решение задачи долговечности для стержня произвольного сечения, работающего при одноосном растяжении, может быть получено точно с использованием формул:

$$t_{\text{ан}}^* = t_0 - \frac{2 \cdot k \cdot Q}{v_0 \cdot d_1} \cdot \left\{ \arctg \frac{2 \cdot k_f \cdot \delta \cdot d_1}{d_1^2 + (2 \cdot a \cdot \delta + b) \cdot b} \right\}; \quad (3)$$

$$t_{\text{ан}}^* = t_0 - \frac{2 \cdot k \cdot Q}{v_0 \cdot d_2} \times \ln \left\{ \frac{(2 \cdot k_f \cdot \delta + b - d_2) \cdot (b + d_2)}{(2 \cdot a \cdot \delta + b + d_2) \cdot (b - d_2)} \right\}. \quad (4)$$

Здесь  $k_f$  – коэффициент формы сечения (для большинства фасонных профилей: уголка, швеллера, двутавра и т.п.);  $b = -P_0$ ;  $c = A_0 + k_f Q$ ;  $A_0, P_0$  – площадь и периметр сечения в начальный момент времени;  $Q$  – величина осевого усилия;  $t_0 = \delta / v_0$ ;  $\delta^*$  – глубина коррозионного износа, соответствующая предельному значению напряжения;  $d_1 = \sqrt{4ac - b^2}$ ;  $d_2 = \sqrt{b^2 - 4ac}$ . Применение формулы (3) или (4) зависит от знака выражения  $4ac - b^2$ .

Эти формулы получены при допущении, что усилия в элементах конструкции постоянны  $Q = \text{const}$ . Большинство же конструкций, представляющих практический интерес, являются статически неопределимыми, а значит, усилия  $Q(\bar{\delta})$  в их элементах изменяются во времени пропорционально интенсивности коррозионных повреждений во всех элементах.

Как показано в работах [2,6], вклад изменения усилий  $Q(\bar{\delta})$  в общее напряженно-деформированное состояние конструкции существенно меньше, чем вклад коррозионного повреждения конкретного элемента  $\delta_i$ . В [6] показано, что аналитические формулы (3) и (4) нельзя использовать для определения долговечности конструкции в целом. Но их можно использовать для определения долговечности элементов конструкции при получении обучающей выборки. Поскольку напряжения в элементах статически неопределимой конструкции находятся численно в каждом узле временной сетки интегрирования СДУ, не важно, чем вызван рост напряжений в элементе конструкции, на котором обучалась сеть: только коррозионными повреждениями этого элемента  $\delta_i$  или же ещё и перераспределением усилий между элементами  $Q(\bar{\delta})$ , вызванным неравномерностью коррозионного повреждения всех элементов конструкции.

Если долговечность конструкционного элемента невозможно определить точно, то эталонное решение  $t_{\text{эТ}}^*$  может быть получено численно путём последовательного уменьшения шага интегрирования до получения асимптотического приближения к точному решению:

$$t_{\text{эТ}}^*(\bar{c}) = \lim_{\Delta t \rightarrow 0} (h_t, \bar{c}). \tag{5}$$

*3 шаг.* На данном этапе задаётся начальный шаг интегрирования  $h_t^0$ . Многими авторами [5,7] показано, что постоянный шаг по времени является нерациональным. Для уменьшения погрешности решения шаг должен уменьшаться в процессе интегрирования. В данной работе шаг интегрирования принято уменьшать обратно пропорционально росту напряжений в элементе конструкции:

$$h_t^i = h_t^{i-1} \frac{\sigma^{i-2}}{\sigma^{i-1}}. \tag{6}$$

*4 шаг.* Следующий этап предполагает численное интегрирование дифференциального уравнения и определение погрешности получаемого решения:

$$\varepsilon = \frac{|t^*(h_t, \bar{c}) - t_{\text{эТ}}^*(\bar{c})|}{t_{\text{эТ}}^*(\bar{c})}. \tag{7}$$

Если полученная погрешность превышает предельно допустимую ( $\varepsilon > [\varepsilon]$ ), то начальный шаг интегрирования  $h_t^0$  уменьшается на некоторую величину  $\delta t$ . После этого осуществляется повторное численное решение дифференциального уравнения. Такая процедура повторяется до тех пор, пока не выполняется условие  $\varepsilon \leq [\varepsilon]$ . В этом случае формируется очередная строка массива обучающих образцов, содержащая вышеперечисленные факторы, влияющие на величину шага интегрирования (элементы вектора  $\bar{c}$ ) и соответствующий шаг интегрирования  $h_t$ .

В результате работы алгоритма получают обучающую выборку, состоящую из параметров конструкции, агрессивной среды и желаемого отклика сети (шаг интегрирования), полученную для конкретного порогового значения предельно допустимой погрешности. Пример учебных образцов для погрешности численного решения СДУ  $\varepsilon \leq 3\%$  показан в табл. 1.

Получение обучающей выборки имеет свои особенности при настраивании сети для решения задачи прогнозирования долговечности и для решения оптимизационной задачи.





Рассмотрим некоторые описанные свойства и особенности ИНС. Как отмечалось выше большую роль в обучении и дальнейшем использовании сети имеет качество обучающей выборки. В том случае если нарушено свойство относительно равномерного представления всех образцов, тогда и качество обучения может быть неудовлетворительным.

Рассмотрим иллюстративный пример со

Таблица 1

**Фрагмент выборки обучающих образцов для нейронной сети**

| $V_0$ , см/год | $P_0$ , см | $A_0$ , см <sup>2</sup> | $\sigma_0$ , МПа | $[\varepsilon]$ , МПа | $\varepsilon[\varepsilon]$ , % | $h_t$ , лет |
|----------------|------------|-------------------------|------------------|-----------------------|--------------------------------|-------------|
| 0,07           | 28,69      | 39,17                   | 710,6            | 220,0                 | 4,2 (5,0)                      | 1,77        |
| 0,07           | 18,91      | 18,42                   | 296,8            | 240,0                 | 1,1 (2,0)                      | 0,93        |
| 0,08           | 27,00      | 57,42                   | 382,5            | 260,0                 | 5,4 (6,0)                      | 1,85        |
| 0,10           | 14,00      | 15,52                   | 724,1            | 220,0                 | 3,4 (4,0)                      | 0,62        |
| 0,10           | 18,58      | 24,68                   | 768,4            | 240,0                 | 6,0 (6,0)                      | 1,58        |
| 0,11           | 21,04      | 26,59                   | 214,4            | 280,0                 | 4,1 (5,0)                      | 0,21        |
| 0,11           | 29,52      | 42,04                   | 670,0            | 240,0                 | 5,8 (6,0)                      | 1,24        |
| ...            | ...        | ...                     | ...              | ...                   | ...                            | ...         |



Примеры ОВ с чётко выделенными кластерами

следующими данными, представленными на рисунке. В этом случае сеть будет выдавать какой-то результат при предоставлении ей значений из «пустых» интервалов, но качественно осуществить обобщение она не сможет.

Эта проблема может быть решена, по мнению автора, двумя способами. Первый способ заключается в пересмотре идеологии получения учебных образцов. Второй предполагает в качестве предварительной обработки данных проводить кластеризацию всего множества учебных образцов с последующим обучением НС для отдельных кластеров. Отметим, что автором использован последний подход к решению проблемы презентативности обучающей выборки для ИНС.

Не останавливаясь детально, следует отметить очевидный факт, что необходимость нормализации входных данных не вызывает никаких сомнений. Это значит, что среднее значение по всему обучающему множеству должно быть близким к нулю, иначе могут возникнуть трудности при сравнении со стандартным от-

клонением.

При практической работе с НС приходится экспериментировать с большим числом различных архитектур сетей. Количество входных элементов определяется из самой постановки задачи выбора рационального шага численного решения СДУ, описывающей процесс накопления геометрических повреждений. Входными элементами, как отмечалось выше, являются: геометрические размеры сечений стержней ( $A_0$ ,  $P_0$ ), начальные  $\sigma_0$  и предельные  $[\sigma]$  напряжения в них и, наконец, скорость коррозии  $v_0$ . Выходным параметром сети будет рациональный шаг интегрирования  $h$ , который, как уже отмечалось, зависит от перечисленных входных данных.

Анализ выбора архитектуры нейронной сети и некоторым проблемам обучения и работы с ними посвящена [8–12]. Отметим, что для обучения НС был использован алгоритм обратного распространения ошибки с учителем в пакетном режиме подачи обучающих образцов без использования момента инерции. Обучающая

Результаты использования ИНС с логистической функцией активации

| Q,<br>кН | v <sub>0</sub> ,<br>см/год | R,<br>см | r,<br>см | t <sub>числ</sub> ,<br>лет | Шаг интегрирования h <sub>t</sub> , лет |                        |
|----------|----------------------------|----------|----------|----------------------------|---|------------------------|
|          |                            |          |          |                            | Архитектура НС 5-7-1                    | Архитектура НС 5-7-7-1 |
| 10       | 0,0859                     | 2,5      | 1,25     | 6,894                      | 0,3911                                  | 0,3939                 |
| 50       | 0,0941                     | 3,5      | 1,75     | 2,553                      | 0,9695                                  | 0,9729                 |
| 25       | 0,1059                     | 3,7      | 2,00     | 6,705                      | 0,2815                                  | 0,2818                 |
| 26       | 0.1141                     | 2,7      | 0,50     | 4,550                      | 0,6430                                  | 0,6534                 |

выборка подавалась в стохастическом режиме, для контроля эффективности обобщения нейронной сети проводились кросс-проверки.

После процесса обучения нейронные сети были протестированы на зарезервированных обучающих (тестовых) образцах, которые не использовались при обучении (результаты приведены в табл. 2).

Нетрудно заметить, что существенного различия в приведенных результатах и погрешностях численного решения не наблюдается. Поэтому для сетей с приблизительно равными ошибками целесообразно выбирать ту сеть, которая имеет более простую архитектуру [9–11].

#### Выводы

Очевидно, что достаточно хорошо себя зарекомендовал подход использования слоистых нейронных сетей прямого распространения при решении задач аппроксимации и им подобных. Сети такой топологии базируются на фундаментальном математическом аппарате [13], позволяющем использовать их в качестве универсальных аппроксимационных систем. В зависимости от решаемой задачи возможно применение каскадных архитектур сетей или синтеза различных их топологий.

Одним из важных этапов для работы с нейронными сетями является получение презентативной обучающей выборки, от качества которой полностью зависит следующий этап – этап обучения нейронной сети. Разработанный алгоритм получения учебных образцов достаточно хорошо зарекомендовал себя при работе со слоистыми сетями, используемыми для решения рассматриваемого класса задач.

#### СПИСОК ЛИТЕРАТУРЫ

1. *Зеленцов Д.Г., Филатов Г.В.* Обзор исследований по применению методов нелинейного математического программирования к оптимальному проектированию конструкций, взаимодействующих с агрессивной средой // *Вопр. химии и хим. технологии.* – 2002. – № 4. – С.108-115.

2. *Зеленцов Д.Г.* Расчёт конструкций с изменяющейся геометрией в агрессивных средах. Стержневые системы: монография. – Днепропетровск: УГХТУ, 2002. – 168 с.

3. *Зеленцов Д.Г., Ляшенко О.А., Науменко Н.Ю.* Информационное обеспечение расчётов корродирующих объектов. Математические модели и концепция проектирования систем: монография. – Днепропетровск: УГХТУ, 2012. – 264 с.

4. *Зеленцов Д.Г., Науменко Н.Ю., Ляшенко О.А.* Информационное обеспечение расчётов корродирующих объектов. Конечно-элементное моделирование: монография. – Днепр: Баланс-Клуб, 2018. – 174 с.

5. *Зеленцов Д.Г., Денисюк О.Р.* Алгоритм решения систем дифференциальных уравнений, моделирующих коррозионный процесс в шарнирно-стержневых конструкциях // *Вісник Національного технічного університету «ХПИ».* Збірник наукових праць. Серія: Математичне моделювання в техніці та технологіях. – Харків: НТУ «ХПИ». – 2016. – № 16 (1188). – С.36-42.

6. *Зеленцов Д.Г., Короткая Л.И.* Технологии вычислительного интеллекта в задачах моделирования динамических систем: монография. – Днепр: Баланс-Клуб, 2018. – 178 с.

7. *Зеленцов Д.Г., Иванова А.П.* Применение нейросетевых моделей в задачах расчёта долговечности корродирующих балочных конструкций // *Науковий вісник НГУ.* – 2015. – № 4. – С.51-56.

8. *Короткая Л.И.* Функціональна підсистема раціонального вибору архітектури нейронної мережі // *Вісник Херсонського національного технічного університету.* – 2017. – Т.1. (Фундаментальні науки). – № 3 (62). – С.55-59.

9. *Haykin S.* *Neural Networks and Learning Machines* (3rd Edition). – Prentice Hall, 2011. – 936 p.

10. *Callan R.* The eddence of neural networks / Robert Callan. (The essence of computer series) Includes bibliographical references and index. – 1998. – 248 p.

11. *Пятковский О.И.* Интеллектуальные информационные системы. (Нейронные сети). Учебное пособие / Алт-гос. техн. Ун-т им. И.И. Ползунова. Барнаул: Изд-во АлтГУ, 2010. – 125 с.

12. *Рутковская Л., Пилинский М., Рутковский Л.* Нейронные сети, генетические алгоритмы и нечёткие системы: Пер. с польск. И.Д. Рудинского. – М.: Горячая линия. – Телеком, 2006. – 452 с.

13. Hecht-Nielsen R. Kolmogorov's Mapping Neural Network Existence Theorem // IEEE First Annual Int. Conf. on Neural Networks. – San Diego. – 1987. – Vol.3. – P.11-13.

Поступила в редакцію 24.04.2018

#### АЛГОРИТМ ОТРИМАННЯ НАВЧАЛЬНИХ ЗРАЗКІВ ДЛЯ НЕЙРОННОЇ МЕРЕЖІ ПРИ РОЗВ'ЯЗАННІ ЗАДАЧ ДОВГОВІЧНОСТІ КОРДУЮЧИХ КОНСТРУКЦІЙ

**Коротка Л.І.**

При розв'язанні задач прогнозування довговічності кородуючих конструкцій пропонується використовувати технології обчислювального інтелекту, зокрема штучні нейронні мережі. Виділяють певні необхідні етапи при їх проектуванні та роботі з ними. Важливим з них є спосіб отримання якісної навчальної вибірки. Подальше настроювання та застосування нейронної мережі безпосередньо залежить від якості отриманих навчальних зразків. Задача прогнозування довговічності є частиною більш загальної задачі – задачі оптимального проектування конструкцій, які функціонують в агресивних зовнішніх середовищах. Тому обчислення прогнозованого значення довговічності (або обчислення функцій обмежень в задачі оптимізації) передбачає багаторазове чисельне розв'язання системи диференціальних рівнянь, яка описує процес накопичення геометричних пошкоджень кородуючої конструкції. Визначення раціональних параметрів чисельного інтегрування в цілому дозволяє підвищити ефективність обчислювального алгоритму. З метою отримання раціонального кроку інтегрування системи диференціальних рівнянь з похибкою, яка не перевищує задану, пропонується використовувати апроксимуючу систему, якою є штучна нейронна мережа. Визначення вхідних параметрів, від яких залежить похибка отриманого розв'язку, дозволяє визначитися з архітектурою нейронної мережі. У роботі виконано аналіз залежностей параметрів чисельного інтегрування та вхідних параметрів в цілому, на підставі якого визначено вектор вхідних параметрів для нейронної мережі. Запропоновано алгоритм отримання елементів вхідного вектора. З метою виключення «порожніх» зон у навчальній вибірці запропоновано попереднє її розбиття на кластери. Такий підхід дозволяє уникнути отримання неякісної вибірки та не знижує ефективності всього обчислювального алгоритму. Запропонована методика отримання навчальних даних дозволяє поліпшити якість навчання нейронної мережі.

**Ключові слова:** штучні нейронні мережі, навчальна вибірка, прогнозування довговічності, кородуючі конструкції.

#### ALGORITHM FOR OBTAINING TRAINING SAMPLES FOR A NEURAL NETWORK IN SOLVING PROBLEMS OF DURABILITY PREDICTION FOR CORRODING STRUCTURES

**Korotka L.I.**

Ukrainian State University of Chemical Technology, Dnipro, Ukraine

When solving the problems of durability prediction for corroding structures, it is proposed to use computational intelligence technologies, in particular, artificial neural networks. It is necessary to allocate certain required stages in their design and exploitation. One of the important steps is the way to obtain a quality training sample. Further tuning and application of the neural network directly depends on the quality of the received training samples. The problem of durability prediction is a part of a more general task, which is the problem of optimal design of structures that function in aggressive external media. Therefore, calculating a predicted durability value (or calculating the constraint functions in an optimization problem) involves solving numerically multiple times a system of differential equations that describes the process of accumulation of geometric damage in a corroding structure. The definition of rational parameters of numerical integration as a whole makes it possible to improve the efficiency of the computational algorithm. In order to obtain a rational step of integrating a system of differential equations with an error not exceeding a given one, it is proposed to use an approximating system, which is an artificial neural network. Determining input parameters on which the error of a solution depends allows one to determine the architecture of a neural network. In this paper, we analyze the dependencies of the parameters of numerical integration and input parameters in general, on the basis of which the vector of input parameters for a neural network is determined. An algorithm for obtaining elements of the input vector is proposed. In order to exclude the «empty» zones in the training sample, it is proposed to prioritize it into clusters. This approach avoids obtaining a poor-quality sample and does not reduce the efficiency of the entire computational algorithm. The proposed method of obtaining training data allows one to improve the quality of neural network training.

**Keywords:** artificial neural networks, training sample, durability prediction, corroding structures.

## REFERENCES

1. Zelentsov D.G., Filatov G.V. Obzor issledovaniy po primeneniyu metodov nelineynogo matematicheskogo programirovaniya k optimalnomu proyektirovaniyu konstruktivnykh vzaimodeystviyushchikh s agressivnoy sredoy [A review of research on the application of methods of nonlinear mathematical programming to the optimal design of structures interacting with an aggressive medium]. *Voprosy khimii i khimicheskoy tekhnologii* [Questions of chemistry and chemical technology], 2002, № 4, pp.108-115. (in Russian).
2. Zelentsov D.G. Raschet konstruktivnykh s izmenyayushchey geometriyey v agressivnykh sredakh. Sterzhnevyye sistemy [Calculation of structures with changing geometry in aggressive media. Rod Systems]. Dnepropetrovsk, Ukrainian State University of Chemical Technology Publ., 2002. 168 p. (in Russian).
3. Zelentsov D.G., Liashenko O.A., Naumenko N.Yu. *Informatsionnoye obespecheniye raschetov korrodiruyushchikh ob'ektov. Matematicheskie modeli i kontseptsiya proektirovaniya sistem* [Information support for calculations of corrosive objects. Mathematical models and concept of systems design]. Dnepropetrovsk: Ukrainian State University of Chemical Technology Publ., 2012. 264 p. (in Russian).
4. Zelentsov D.G., Naumenko N.Yu., Liashenko O.A. *Informatsionnoye obespecheniye raschetov korrodiruyushchikh ob'ektov. Konechno-elementnoye modelirovaniye* [Information support for the calculation of corrosive objects. Finite Element Modeling]. Dnepr: Balans-Klub, 2018. 174 p. (in Russian).
5. Zelentsov D.G., Denisyuk O.R. Algoritm resheniya sistem differentsialnykh uravneniy. modeliruyushchikh korroziyonyy protsess v sharnimo-sterzhnevyykh konstruktivnykh [Algorithm for Solving Differential Equations Systems Modeling Corrosion Process in Hinge-Rod Structures] // *Visnik Natsionalnogo tekhnichnogo universitetu «KhPI»*. [Bulletin of the National Technical University «KhPI»]. Zbirnik naukovikh prats. Seriya: Matematichne modeliyuvannya v tekhnitsi ta tekhnologiyakh, Kharkiv: NTU «KhPI», 2016, № 16 (1188), pp.36-42. (in Russian).
6. Zelentsov D.G., Korotkaya L.I. *Tekhnologii vychislitel'nogo intellekta v zadachakh modelirovaniya dinamicheskikh sistem* [Technologies of computational intelligence in modeling problems of dynamic systems]. Dnepr: Balans-Klub. 2018, 178 p. (in Russian).
7. Zelentsov D.G., Ivanova A.P. Primneneniye neyrosetevykh modeley v zadachakh rascheta dolgovechnosti korrodiruyushchikh balochnykh konstruktivnykh [Application of neural network models in problems of calculating the durability of corrosive beam structures] // *Naukoviy visnik NGU* [Scientific Bulletin of National Mining University], 2015, № 4, pp.51-56. (in Russian).
8. Korotka L.I. *Funksionalna pidsystema ratsionalnogo vyboru arkhitektury neironnoi mrezi* [Functional subsystem of the rational choice of the architecture of the neural network] // *Visnyk Khersonskoho natsionalnogo tekhnichnogo universitetu* [Visnyk of Kherson National Technical University], 2017, no. 3 (62), Tom I., pp.55-59. (in Ukrainian).
9. Haykin S. *Neural Networks and Learning Machines* (3rd Edition). Prentice Hall, 2011. 936 p.
10. Callan R. The evidence of neural networks. *Includes bibliographical references and index*. 1998. 248 p.
11. Pyatkovskiy O.I. *Intellektualnyye informatsionnyye sistemy. (Neyronnyye seti)*. Uchebnoye posobiye [Intelligent information systems. (Neural networks).] / Alt.gos. tekhn. Un-t im. I.I. Polzunova. Barnaul: Izd-vo AltGTU. 2010, 125 p. (in Russian).
12. Rutkovskaya L., Pilinskiy M., Rutkovskiy L. *Neyronnyye seti. geneticheskiye algoritmy i nechetkiye sistemy* [Neural networks, genetic algorithms and fuzzy systems]: Per. s polsk. I.D. Rudinskogo. M.: Goryachaya liniya. Telekom. 2006, 452 p. (in Russian).
13. Hecht-Nielsen R. Kolmogorov's Mapping Neural Network Existence Theorem // *IEEE First Annual Int. Conf. on Neural Networks*, San Diego, 1987, Vol. 3, pp.11-13.