

УДК 0048:681.3

О.В. ЧОПОРОВА, С.В. ЧОПОРОВ, А.О. ЛІСНЯК
Запорізький національний університет

ВИКОРИСТАННЯ МАШИННОГО НАВЧАННЯ ДЛЯ ПРОГНОЗУВАННЯ НАПРУЖЕНО-ДЕФОРМОВАНОГО СТАНУ КРУГЛОЇ ПЛАСТИНКИ

Штучні нейронні мережі застосовуються у різноманітних сферах, пов'язаних з обробкою інформації. Наприклад, в таких галузях як: розпізнавання образів, задачі оптимізації, теорія керування, вирішення інженерних задач проектування, екстраполяція та прогнозування. Існує велика кількість програмного забезпечення, що використовує можливості технологій штучних нейронних мереж. У сучасному виробництві широке поширення одержали системи автоматизованого проектування, які дозволяють проектувати технологічні процеси з меншими витратами часу та засобів, зі збільшенням точності спроектованих процесів і програм обробки.

Розробка методів і моделей машинного навчання дозволяє робити швидкі оцінки необхідних параметрів стану об'єкту. З практичної точки зору моделі машинного навчання для прогнозування значень параметрів стану конструкції можуть слугувати як інтерактивні асистенти у процесі проектування. Одним із актуальних питань застосувань нейронних мереж є їх структурна оптимізація, тобто, вибір оптимальної кількості шарів, нейронів, функцій активації тощо. У даній роботі розглянуто використання машинного навчання для прогнозування напружено-деформованого стану круглої пластинки. Розроблено алгоритм генерації параметрів круглої пластинки. Побудовано модель штучної нейронної мережі для прогнозування напружено-деформованого стану круглої пластинки. Тестову вибірку, яка містить можливі стани пластинки у залежності від геометричних і фізико-механічних параметрів, побудовано з використанням аналітичних формул і методу скінченних елементів. Побудовано моделі навчання на базі штучних нейронних мереж. Побудовані моделі дозволяють прогнозувати прогин у центрі пластинки, а також максимальне значення інтенсивності напружень за Мізесом. Основною перевагою штучної нейронної мережі є швидкість прогнозування. Обчислення необхідних характеристик відбувається майже миттєво (мілісекунди). Отже, «натреновані» штучні нейронні мережі можуть слугувати як інтерактивні помічники у процесі проектування.

Ключові слова: машинне навчання, штучна нейронна мережа, алгоритм генерації, напружено-деформований стан, пластинка, прогнозування.

О.В. ЧОПОРОВА, С.В. ЧОПОРОВ, А.А. ЛІСНЯК
Запорожский национальный университет

ИСПОЛЬЗОВАНИЕ МАШИННОГО ОБУЧЕНИЯ ДЛЯ ПРОГНОЗИРОВАНИЯ НАПРЯЖЕННО-ДЕФОРМИРОВАННОГО СОСТОЯНИЯ КРУГЛОЙ ПЛАСТИНКИ

Искусственные нейронные сети применяются в различных сферах, связанных с обработкой информации. Например, в таких областях как: распознавание образов, задачи оптимизации, теория управления, решения инженерных задач проектирования, экстраполяция и прогнозирование. Существует большое количество программного обеспечения, использующего возможности технологий искусственных нейронных сетей. В современном производстве широкое распространение получили системы автоматизированного проектирования, которые позволяют проектировать технологические процессы с меньшими затратами времени и средств, с увеличением точности спроектированных процессов и программ обработки.

Разработка методов и моделей машинного обучения позволяет делать быстрые оценки необходимых параметров состояния объекта. С практической точки зрения модели машинного обучения для прогнозирования значений параметров состояния конструкции могут служить как интерактивные ассистенты в процессе проектирования. Одним из актуальных вопросов применений нейронных сетей является их структурная оптимизация, то есть, выбор оптимального количества слоев, нейронов, функций активации и тому подобное. В данной работе рассмотрено использование машинного обучения для прогнозирования напряженно-деформированного состояния круглой пластинки. Разработан алгоритм генерации параметров круглой пластинки. Построена модель искусственной нейронной сети для прогнозирования напряженно-деформированного состояния круглой пластинки. Тестовая выборка, которая содержит возможные состояния пластинки в зависимости от

геометрических и физико-механических параметров, построена с использованием аналитических формул и метода конечных элементов. Построены модели обучения на базе искусственных нейронных сетей. Построенные модели позволяют прогнозировать прогиб в центре пластинки, а также максимальное значение интенсивности напряжений по Мизесу. Основным преимуществом искусственной нейронной сети является скорость прогнозирования. Вычисления требуемых характеристик происходит почти мгновенно (миллисекунды). Итак, «натренированные» искусственные нейронные сети могут служить как интерактивные помощники в процессе проектирования.

Ключевые слова: машинное обучение, искусственная нейронная сеть, алгоритм генерации, напряженно-деформированное состояние, пластинка, прогнозирование.

O.V. CHOPOROVA, S.V. CHOPOROV, A.O. LISNIAK
Zaporizhzhia National University

USING MACHINE LEARNING TO PREDICT THE STRESS-STRAIN STATE OF A CIRCULAR PLATE

Artificial neural networks are used in various areas related to information processing. For example, in such areas as: pattern recognition, optimization problems, control theory, engineering design problems, extrapolation and forecasting. There is a large amount of software that uses the capabilities of artificial neural network technology. In modern production, computer-aided design systems have become widespread, which allow to design technological processes with less time and money, with increasing accuracy of the designed processes and processing programs.

The development of machine learning methods and models allows you to make quick estimates of the necessary parameters of the state of the object. From a practical point of view, machine learning models for predicting the values of structural parameters can serve as interactive assistants in the design process. One of the topical issues in the application of neural networks is their structural optimization, the choice of the optimal number of layers, neurons, activation functions and so on. In this paper, the use of machine learning to predict the stress-strain state of a circular plate is considered. An algorithm for generating circular plate parameters has been developed. A model of an artificial neural network for predicting the stress-strain state of a circular plate is constructed. The test sample, which contains the possible states of the plate depending on the geometric and mechanical parameters, was constructed using analytical formulas and the finite element method. Learning models based on artificial neural networks are built. The constructed models allow predicting the deflection in the center of the plate, as well as the maximum value of the stress intensity according to Mises. The main advantage of an artificial neural network is the speed of prediction. The calculation of the required characteristics is almost instantaneous (milliseconds). Thus, "trained" artificial neural networks can serve as interactive assistants in the design process.

Keywords: machine learning, artificial neural network, algorithm, stress-strain state, plate, prediction, regression.

Постановка проблеми

Необхідність в дослідженні поведінки інженерних конструкцій виникає в різноманітних галузях, таких як будівництво, автомобілебудування, ракетобудування і ін. Машинне навчання дозволяє отримати моделі для миттєвої оцінки параметрів стану об'єкта. Таким чином, розробка методів машинного навчання для прогнозування поведінки інженерних конструкцій є актуальною.

Класичні методи математичного моделювання дозволяють робити прогнози з необхідною точністю, але підготовка математичних моделей і проведення відповідних обчислювальних експериментів можуть бути тривалими за часом. Методи машинного навчання дозволяють адаптувати свою структуру шляхом обробки вибірки даних. Вони дозволяють розширити можливості математичного моделювання за допомогою обліку результатів обчислювальних і натурних експериментів. З практичної точки зору моделі машинного навчання для прогнозування значень параметрів стану конструкції можуть служити інтерактивними асистентами в процесі проектування.

Завдання прогнозування параметрів стану об'єкта по його геометричним і фізико-механічними параметрами можна віднести до класу задач регресії. Для

прогнозування напружено-деформованого стану круглої пластинки необхідно враховувати такі параметри: радіус, товщину, модуль Юнга, коефіцієнт Пуассона, навантаження.

Аналіз останніх досліджень і публікацій

На сьогоднішній день великої популярності в світі набула така галузь штучного інтелекту як нейронні мережі. Штучні нейронні мережі застосовуються у різноманітних сферах, пов'язаних з обробкою інформації. Наприклад, в таких галузях як: розпізнавання образів, задачі оптимізації, теорія керування, вирішення інженерних задач проектування, екстраполяція та прогнозування. Існує велика кількість програмного забезпечення, що використовує можливості технологій штучних нейронних мереж. Прикладом можуть бути універсальні програми, що вирішують задачі від розпізнавання рукописного тексту до задач прогнозування. Таким чином, вивчення методів тренування нейронних мереж в даний час є актуальною темою.

Наприклад, у роботах [1–3] досліджено можливості машинного навчання для розв'язання задач механіки руйнування. Зокрема, у роботі [1] для навчання нейронної мережі прогнозувати можливі зони руйнування балок використано дані 64 обчислювальних експериментів та 3 натурних. У роботі [8] розроблено нейронну мережу, яка базується на фільтрі Калмана, для прогнозування руйнування швидкісної дороги на мосту шляхом обробки даних про температуру та коливання. У роботі [4] для прогнозування руйнування за даними про вібрації розроблено модель на основі самоорганізаційної карти Кохонена. У роботі [2] досліджено можливості нейронних мереж для прогнозування максимальних переміщень у залізничних балках. Модель нейронної мережі побудовано як функцію двох змінних: фрикційного параметра та швидкості навантаження. Для навчання використано 663 точки, що дозволило отримати максимальну похибку відносно скінченно-елементної моделі у 5,4%. Модель нейронної мережі для прогнозування критичного навантаження (у контексті втрати стійкості) двотаврової балки з отворами розроблено у роботі [3]. Розроблена модель враховує сім геометричних параметрів і дозволяє обчислити критичне навантаження з точністю у межах від 3,7% до 0,4% за час, менший однієї мілісекунди. Спосіб підвищення точності та ефективності обчислення функцій обмежень у задачах оптимального проектування конструкцій на базі апроксимації похибки розв'язання системи диференціальних рівнянь запропоновано у роботі [5]. Модель нейронної мережі використовується для обчислення похибки аналітико-чисельного алгоритму обчислення довговічності балочної конструкції відносно скінченно-елементного розв'язку. Покроковий алгоритм донавчання нейронної моделі, який дозволяє розв'язувати задачі динаміки будівельних конструкцій, розроблено у роботі [6]. Розроблений алгоритм дозволяє прогнозувати напружено-деформований стан конструкції, яка знаходиться під дією тривалого або короткочасного навантаження.

Отже, аналіз останніх досліджень і публікацій дозволяє зробити висновок про актуальність розробки моделей на базі нейронних мереж для прогнозування напружено-деформованого стану з використанням генетичного алгоритму. Можливості нейронних мереж для прогнозування стану оболонкових конструкцій потребують дослідження.

Мета дослідження

Мета дослідження – розробка штучної нейронної мережі для прогнозування напружено-деформованого стану круглої пластинки із ізотропного матеріалу, яка знаходиться під дією рівномірно розподіленого по поверхні поперечного тиску.

Об'єкт дослідження – напружено-деформований стан круглої пластинки із ізотропного матеріалу, яка знаходиться під дією рівномірно розподіленого по поверхні поперечного тиску.

Предмет дослідження – методи і моделі машинного навчання для регресійного аналізу.

Задачі дослідження:

1. Розробити алгоритм формування вибірки для навчання та тестування моделей.
2. Розробити нейронну мережу для прогнозування максимального прогину пластинки.
3. Розробити нейронну мережу для прогнозування максимальних значень прогину та інтенсивності напружень за Мізесом у пластинці.

Викладення основного матеріалу дослідження

1. Нейромережевий метод моделювання напружено-деформованого стану круглої пластини

Розглянемо круглу пластинку з параметрами: a – радіус, h – товщина, E – модуль пружності матеріалу, ν – коефіцієнт Пуассона, q – поперечна сила. Якщо навантаження, що діє на круглу пластинку, розподілене по ній симетрично відносно осі, що перпендикулярна до площини пластинки та проходить через її центр, тоді вигнута поверхня, в яку перетвориться серединна площина пластинки, також буде симетричною. В усіх точках, рівновіддалених від центру пластинки, прогини будуть однакові, тому їх можна розглядати в одному діаметральному перетині, що проходить через вісь симетрії. Відповідно до [9], початок координат O знаходиться в центрі невингнutoї пластинки, через r позначено радіальну відстань точок, що лежать у серединній площині, а через ω – їх прогин донизу.

Прогин круглої пластинки, що поперечно навантажена, описує таке рівняння:

$$\frac{d}{dr} \left[\frac{1}{r} \frac{d}{dr} \left(r \frac{d\omega}{dr} \right) \right] = \frac{Q}{D}, \quad (1)$$

де Q – поперечна сила, що приходить на одиницю довжини циліндричного перерізу радіуса r ;

r – радіус;

D – жорсткість пластинки при вигині, яка має вигляд такого рівняння:

$$D = \frac{Eh^3}{12(1 - \nu^2)}, \quad (2)$$

де E – модуль пружності матеріалу,

ν – коефіцієнт Пуассона,

h – товщина.

Для випадку рівномірного навантаження q модель отримує такий вигляд:

$$\frac{d}{dr} \left[\frac{1}{r} \frac{d}{dr} \left(r \frac{d\omega}{dr} \right) \right] = \frac{qr}{2D}. \quad (3)$$

Якщо пластинка затиснена по контуру, тоді прогин можна представити у такому вигляді:

$$\omega = \frac{q}{64D} (a^2 - r^2)^2, \quad (4)$$

де a – радіус, r – відстань від центра до поточної точки.

Найбільший прогин спостерігається у центрі пластинки, тоді його величина буде дорівнювати:

$$\omega_{max} = \frac{qa^4}{64D}. \quad (5)$$

Найбільша напруга спостерігається на контурі пластинки і буде дорівнювати:

$$(\sigma_r)_{max} = \frac{3qa^2}{4h^2}. \quad (6)$$

2. Генерація навчальної вибірки круглої пластини

Для визначення напружено-деформованого стану круглої пластинки необхідні значення таких параметрів як: a – радіус пластинки, h – товщина пластинки, E – модуль пружності матеріалу, ϑ – коефіцієнт Пуассона, q – поперечна сила.

Параметри пластинки генеруються випадковим чином з такими обмеженнями:

- $a \in [0.1; 4]$ (м);
- $h \in [0.01; 0.05]$ (м);
- $E \in [50000; 300000]$ (MPa);
- $\vartheta \in [0; 0.45]$;
- $q \in [0.01; 0.1]$ (MPa).

Алгоритм генерації даних круглої пластинки представлено нижче:

algorithm generation_circular_plate

input:

n (кількість значень у вибірці)

output:

S (вибірка для навчання)

begin

$S \leftarrow \emptyset$

for $i \leftarrow 1$ to n **do**

begin

$a \leftarrow \text{random}(0,1; 4)$

$h \leftarrow \text{random}(0,01; 0,05)$

$q \leftarrow \text{random}(0,01; 0,1)$

$E \leftarrow \text{random}(50000; 300000)$

$\vartheta \leftarrow \text{random}(0; 0,45)$

$D \leftarrow \frac{Eh^3}{12(1-\vartheta^2)}$

$\omega_{max} \leftarrow \frac{qa^4}{64D}$

$\sigma_{max} \leftarrow \frac{3qa^2}{4h^2}$

$$S \leftarrow S \cup (a, h, E, \vartheta, q, \omega_{max}, \sigma_{max})$$

end

end

де D – жорсткість пластинки,

ω_{max} – максимальний прогин,

σ_{max} – інтенсивність напружень.

У результаті генерації 10000 даних отримаємо таблицю з результатами по кожному параметру в залежності від заданих обмежень.

3. Архітектура нейронної мережі

Для прогнозування прогину та інтенсивності напружень круглої пластинки розглянемо дві штучні нейронні мережі: 1 – для визначення максимального прогину, 2 – для прогнозування інтенсивності напружень. Структура нейронної мережі для визначення максимального прогину має вигляд, наведений рис. 1. Перший шар зовнішній і складається з 5 параметрів, що були використані під час генерації даних. Внутрішніх шарів у моделі – 5 по 30 нейронів у кожному. Останній шар (також зовнішній) має кількість нейронів, яка дорівнює кількості вихідних значень, тобто 1 нейрон для обчислення прогину.

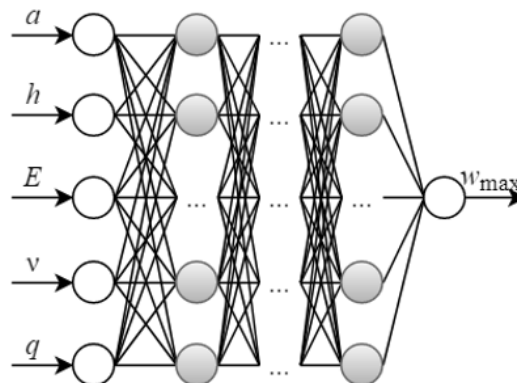


Рис. 1. Модель нейронної мережі для визначення максимального прогину

Структура нейронної мережі для прогнозування інтенсивності напружень σ_{max} у круглій пластинці має шість вхідних параметрів у зовнішньому шарі: $a, h, E, q, \vartheta, \omega_{max}$ (рис. 2), п'ять внутрішніх прихованих шарів по 30 нейронів у кожному, та зовнішній вихідний шар з одним нейроном для прогнозування інтенсивності напружень.

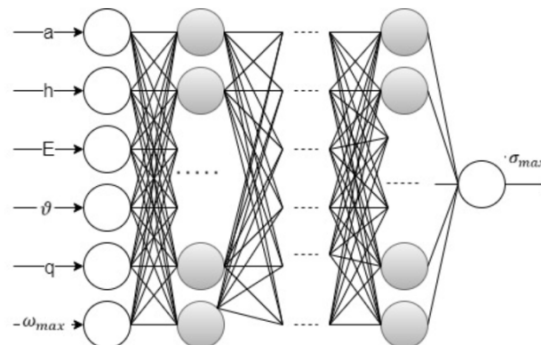


Рис.2. Модель нейронної мережі для прогнозування інтенсивності напружень

4. Обчислювальний експеримент

Під час обчислювального експерименту для визначення максимального прогину та напруження круглої пластинки було використано у створеній нейронній мережі різну кількість внутрішніх шарів з різною кількістю нейронів в них. Експеримент показав, що найкращі результати можна отримати, використовуючи п'ять внутрішніх шарів з 30 нейронами.

У результаті навчання 2000 епох досягнуто найкраще значення середньоквадратичної похибки (рис. 3).

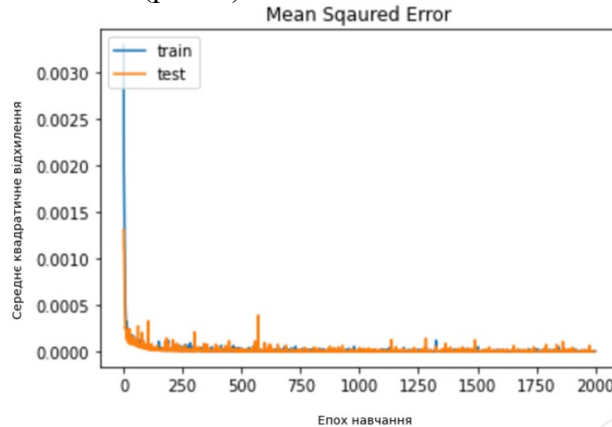


Рис. 3. Графік середньоквадратичної похибки у нейронній мережі

На рис. 4 порівнюються значення прогину, отримані за допомогою аналітичної формули, зі значеннями, отриманими за допомогою нейронної мережі.

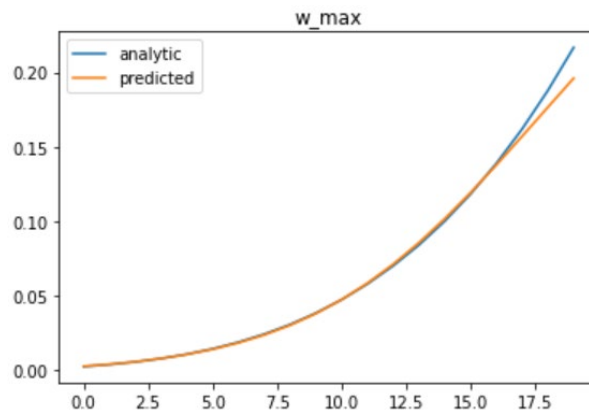


Рис. 4. Порівняння значень прогину, отриманих за допомогою аналітичної формули, зі значеннями, отриманими за допомогою нейронної мережі

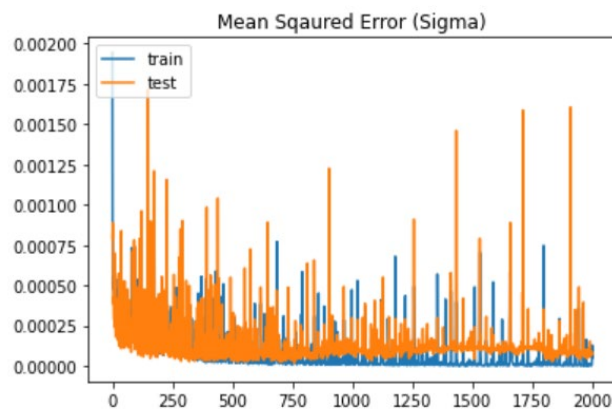


Рис. 5. Середньоквадратична похибка інтенсивності напружень

У результаті 2000 епох отримано середньоквадратичну похибку інтенсивності напружень (рис. 5).

На рисунках 6, 7 порівнюються значення інтенсивності напружень у залежності від значень радіуса пластинки (рис. 6) та її товщини (рис. 7).

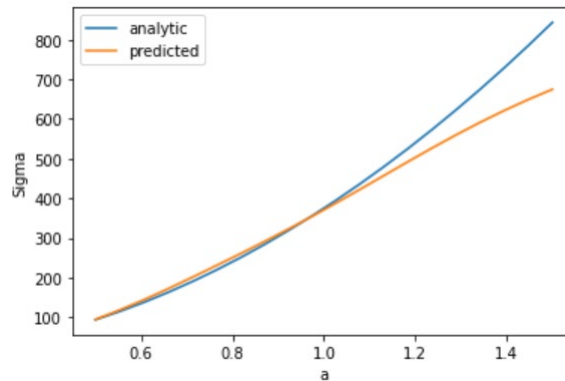


Рис. 6. Порівняння значень, отриманих аналітично та за допомогою машинного навчання інтенсивності напружень у залежності від радіусу пластинки

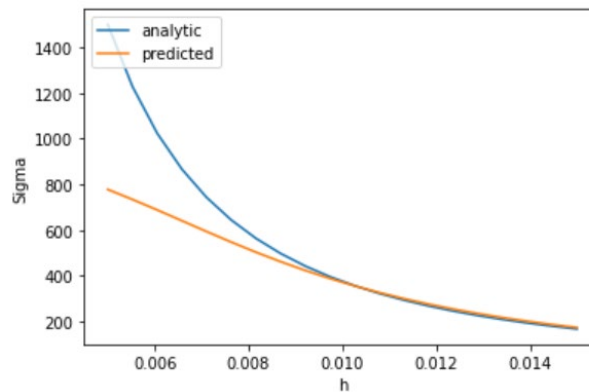


Рис. 7. Порівняння значень, отриманих аналітично та за допомогою машинного навчання інтенсивності напружень у залежності від товщини пластинки

Отже, штучні нейронні мережі дозволяють робити прогноз одночасно декількох характеристик напружено-деформованого стану конструкції.

Висновки

У відповідності до мети роботи розроблено штучну нейронну мережу для прогнозування напружено-деформованого стану круглої пластинки із ізотропного матеріалу, яка знаходиться під дією рівномірно розподіленого по поверхні поперечного тиску. Розроблено нейронну мережу для прогнозування максимального прогину пластинки. Мережева модель значно гнучкіша з точки зору можливості обробки більш складних даних. Розроблено нейронну мережу для прогнозування максимальних значень прогину та інтенсивності напружень за Мізесом у пластинці. Штучна нейронна мережа дозволила прогнозувати обидві характеристики стану пластинки з точністю у межах 10%.

Основною перевагою штучної нейронної мережі є швидкість прогнозування: обчислення необхідних характеристик у порівнянні з методом скінченних елементів відбувається майже миттєво (мілісекунди). Отже, «натреновані» штучні нейронні мережі можуть слугувати інтерактивними помічниками у процесі проектування.

Перспективи подальших досліджень пов'язані з розробкою штучних нейронних мереж, які дозволять прогнозувати напружено-деформований стан за кресленням або

зображенням оболонкових конструкцій з використанням машинного зору і алгоритмів класифікації.

Список використаної літератури

1. Abambres M., Marcy M., Doz G. Potential of Neural Networks for Structural Damage Localization engrXiv. 2018. P. 3–26. URL: <https://engrxiv.org/rghpf/> DOI: 10.31224/osf.io/rghpf.
2. Abambres M., Corrêa R., A. P. da Costa, F. Simões F. Potential of neural networks for maximum displacement predictions in railway beams on frictionally damped foundations engrXiv. 2019. P. 2–31. URL: <https://engrxiv.org/m3b7j/> DOI: 10.31224/osf.io/m3b7j/
3. Abambres M., Rajana K., Tsavdaridis K., Ribeiro T. Neural Network-based formula for the buckling load prediction of I-section cellular steel beams engrXiv. 2018. P. 2–17. URL: <https://engrxiv.org/wg7hd/> DOI: 10.31224/osf.io/wg7hd.
4. Onur Avci P. O., Abdeljaber A. O. Self-Organizing Maps for Structural Damage Detection: A Novel Unsupervised Vibration-Based Algorithm. *Journal of Performance of Constructed Facilities*. 2016. Vol. 30. Iss. 3. P. 1–11.
5. Зеленцов Д. Г. Нейронные сети как средство повышения точности и эффективности решения задач оптимизации. *Комп'ютерне моделювання: аналіз, управління оптимізація*. 2018. № 2. С. 18–26.
6. Мазуров В. Д. Математические методы распознавания образов : уч.пособие, 2-е изд. Екатеринбург : Урал. ун-т, 2010. 101 с.
7. Hany Sallam, Carlo S. Regazzoni, Ihab Talkhan, and Amir Atiya. Evolving neural networks ensembles nnes. *IAPR Workshop on Cognitive Information Processing*, 2008. P. 142–147.
8. Jin C., Jang S, Sun X., Li J., Christenson R. Damage detection of a highway bridge under severe temperature changes using extended Kalman filter trained neural network *Journal of Civil Structural Health Monitoring*. 2016. Vol. 6. P. 545–560.
9. Тимошенко С.П., Войновский-Кригер С. Пластинки и оболочки. 1966. С. 66–72. URL: pnu.edu.ru/media/filer_public/2013/04/10/5-5_timoshenko_1966.pdf

References

1. Abambres, M., Marcy, M., & Doz, G. (2018). Potential of Neural Networks for Structural Damage Localization engrXiv. pp. 3–26. URL: <https://engrxiv.org/rghpf/> DOI: 10.31224/osf.io/rghpf.
2. Abambres, M., Corrêa, R., A. P. da Costa, & F. Simões, F. (2019). Potential of neural networks for maximum displacement predictions in railway beams on frictionally damped foundations engrXiv. pp. 2–31. URL: <https://engrxiv.org/m3b7j/> DOI: 10.31224/osf.io/m3b7j.
3. Abambres, M., Rajana, K., Tsavdaridis, K., & Ribeiro, T. (2018). Neural Network-based formula for the buckling load prediction of I-section cellular steel beams engrXiv. pp. 2–17. URL: <https://engrxiv.org/wg7hd/> DOI: 10.31224/osf.io/wg7hd.
4. Onur Avci, P. O., & Abdeljaber, A. O. (2016). Self-Organizing Maps for Structural Damage Detection: A Novel Unsupervised Vibration-Based Algorithm. *Journal of Performance of Constructed Facilities*. **30**, 3, 1–11.
5. Zelentsov, D. G. (2018). Neyronnyie seti kak sredstvo povyisheniya tochnosti i effektivnosti resheniya zadach optimizatsii. *Komp'yuterne modelyuvannya: anallz, upravlnnya optimlzatsIya*. **2**, 18–26.
6. Mazurov, V. D. (2010). Matematicheskie metodyi raspoznavaniya obrazov : uch.posobie, 2-e izd. Ekaterinburg : Ural. un-t

7. Hany Sallam, Carlo S. Regazzoni, Ihab Talkhan, & Amir Atiya. (2008). Evolving neural networks ensembles nnes. *IAPR Workshop on Cognitive Information Processing*, pp. 142–147.
8. Jin, C., Jang, S, Sun, X., Li, J., & Christenson, R. (2016). Damage detection of a highway bridge under severe temperature changes using extended Kalman filter trained neural network *Journal of Civil Structural Health Monitoring*. **6**, 545 – 560.
9. Timoshenko, S.P., & Voynovskiy-Kruger, S. (1966). *Plastinki i obolochki*. 1966 URL: pnu.edu.ru/media/filer_public/2013/04/10/5-5_timoshenko_1966.pdf. pp. 66-72.

Чопорова Оксана Володимирівна – аспірант кафедри програмної інженерії Запорізького національного університету, e-mail: o.choporova@gmail.com ORCID: 0000-0003-3167-7869

Чопоров Сергій Вікторович – д.т.н., доцент, професор кафедри програмної інженерії Запорізького національного університету. e-mail: s.choporoff@znu.edu.ua ORCID: 0000-0001-5932-952X

Лісняк Андрій Олександрович – к.ф.-м.н., доцент, завідувач кафедри програмної інженерії Запорізького національного університету, e-mail: andrey.lisnyak@gmail.com ORCID: 0000-0001-9669-7858