

УДК 004.94:004.032.26

DOI <https://doi.org/10.32782/IT/2025-1-13>

Анастасія КАЛЮЖНЯК

доктор філософії, доцент кафедри комп'ютерних наук, Запорізький національний університет, вул. Університетська, 66, м. Запоріжжя, Україна, 69600

ORCID: 0000-0002-4837-7566

Scopus Author ID: 59521964300

Бібліографічний опис статті: Калюжняк, А. (2025). Проектування адаптивних дискретних моделей із застосуванням нейронних мереж. *Information Technology: Computer Science, Software Engineering and Cyber Security*, 91–97, doi: <https://doi.org/10.32782/IT/2025-1-13>

ПРОЄКТУВАННЯ АДАПТИВНИХ ДИСКРЕТНИХ МОДЕЛЕЙ ІЗ ЗАСТОСУВАННЯМ НЕЙРОННИХ МЕРЕЖ

У сучасному машинобудуванні широке поширення отримали системи автоматизованого проектування, які будують технологічні процеси з меншими витратами засобів та часу, збільшуючи точність спроектованих процесів і програм обробки, що скоротить витрати матеріалів та час на обробку.

Розвиток нових методів і моделей нейронних мереж дозволяє виконувати швидкі оцінки необхідних параметрів стану об'єктів. На практиці, моделі машинного навчання використовують для прогнозування значень параметрів стану конструкцій. Тому на даний час актуальне питання застосування нейронних мереж, їх структурна оптимізація, а саме, вибір необхідної кількості шарів, функцій активації, нейронів тощо. Дані заходи можуть виконуватися як вручну, за умови невеликої кількості параметрів, так і автоматично.

Мета роботи полягає в розробці штучної нейронної мережі для побудови адаптивних дискретних моделей з використанням генетичного алгоритму, який може бути використаний в аеродинамічних структурах (моделювання аеродинамічного крила), інженерних задачах та машинобудуванні.

Методологія. У даній статті розглянуто особливості побудови адаптивних дискретних моделей з використанням генетичного алгоритму для оптимізації параметрів нейронної мережі. Важливим етапом реалізації генетичних алгоритмів є вибір генетичних операторів: селекції, відбору, кросоверу, мутації. Визначення цих операторів впливає на ефективність методу в цілому.

Наукова новизна дослідження полягає в реалізації нових методів та підходів в побудові геометричних моделей для автоматизації проєктувальних робіт з використанням нейронних мереж, а саме генетичного алгоритму. Для реалізації даного дослідження використовується модель побудована за допомогою R-функцій в послідовній побудові та за допомогою генетичного алгоритму, що відображає свої результати в порівняльній часовій характеристиці.

Висновки. Дослідження показало, що побудова адаптивної дискретної моделі за допомогою генетичного алгоритму забезпечує збільшення точності та має часову ефективність. А отже, дане дослідження може бути корисним для вирішення інженерних задач, в машинобудуванні тощо.

Ключові слова: R-функції, дискретна модель, машинне навчання, штучна нейронна мережа, генетичний алгоритм, популяція, фітнес-функція, схрещування, мутація, прогнозування.

Anastasiia KALIUZNIAK

Doctor of Philosophy, Associate Professor at the Department of Computer Science, Zaporizhzhia National University, 66, Universytetska Str., Zaporizhzhia, Ukraine, 69600

ORCID: 0000-0002-4837-7566

Scopus Author ID: 59521964300

To cite this article: Kaliuzhniak, A. (2025). Proiektuvannia adaptivnykh dyskretnykh modelei iz zastosuvanniam neironnykh merezh [Design of adaptive discrete models with the application of neural networks]. *Information Technology: Computer Science, Software Engineering and Cyber Security*, 91–97, doi: <https://doi.org/10.32782/IT/2025-1-13>

DESIGN OF ADAPTIVE DISCRETE MODELS WITH THE APPLICATION OF NEURAL NETWORKS

In modern mechanical engineering, automated design systems have become widespread, building technological processes in more cost and time efficient way, increasing the accuracy of designed processes and processing programs, with the further reduction of material consumption and processing time.

The development of new methods and neural network models enables rapid estimation of the required parameters of the state of objects. In practice, machine learning models are used to predict the values of the parameters of the state of structures. Therefore, the application of neural networks, their structural optimization, namely, the selection of the necessary number of layers, activation functions, neurons, etc., currently remains an urgent issue.

These activities can be performed both manually, provided that there is a small number of parameters, and automatically.

The purpose of the work is to develop an artificial neural network for building adaptive discrete models using a genetic algorithm, which can be applied in aerodynamic structures (airfoil modeling), engineering problems and mechanical engineering.

Methodology. This article examines the features of building adaptive discrete models using a genetic algorithm to optimize neural network parameters. An important stage in the implementation of genetic algorithms is the choice of genetic operators: selection, data sampling, crossover, mutation. The definition of these operators impacts on the effectiveness of the method as a whole.

The scientific novelty of the research lies in the implementation of new methods and approaches in the construction of geometric models for the automation of design work using neural networks, namely the genetic algorithm. For the implementation of the given research, a model built by means of R-functions in a sequential construction and a genetic algorithm is used, displaying its results in a comparative time characteristic.

Conclusions. The study revealed that building an adaptive discrete model using a genetic algorithm provides an accuracy increase and time-efficiency. Therefore, this study can be useful for solving engineering problems, in mechanical engineering, etc.

Key words: R-functions, discrete model, machine learning, artificial neural network, genetic algorithm, population, fitness-function, crossover, mutation, prediction.

Вступ. Використання нейромережевої моделі в процесі проєктування об'єкту відрізняється від інших підходів завдяки можливості її донавчання. Модель повинна вдосконалюватися з урахуванням нової інформації. Вона може супроводжувати функціонування системи, отримувати додаткову інформацію та на основі її донавчатися. Ця можливість нейромережевої технології дозволяє вдосконалювати як саму конструкцію, так і її управління.

Важливою перевагою використання нейромережевого підходу може бути те, що архітектура нейромережевої моделі може відображати природу матеріалу та реальні властивості конструкції. Цей підхід відкриває нові можливості для створення спеціалізованих керуючих нейромереж, вбудованих безпосередньо в проєктований об'єкт. Крім того, він дозволяє створювати візуалізацію конструкцій (як керованих, так і некерованих). Такими візуалізаторами можуть виступати штучні нейронні мережі раціональної архітектури, навчені і внаслідок цього наповнені деяким змістом, які відображатимуть властивості конструкцій. Для розв'язання задач проєктування найчастіше використовується генетичний алгоритм, а саме для оптимального проєктування в машинобудуванні та будівельних конструкцій.

Літературний огляд. Одне з актуальних питань, що стосується застосувань нейронних мереж є їх структурна оптимізація, а саме, правильний вибір оптимальної кількості шарів, функцій активації, нейронів, тощо. Дана оптимізація може проводитися вручну, за умови відносно невеликої кількості параметрів, і в автоматичному режимі. Генетичні алгоритми досить давно використовуються для задач структурної

оптимізації нейронних мереж (Abambres, M., 2018; Jin C., 2016; Onur Avci P. O., 2016), проте, вони менше використовувались для підбору параметрів в побудові дискретних моделей.

Робота (Li K., 2015) представляє собою розроблений покроковий алгоритм навчання нейронної моделі, яка дозволить розв'язувати задачі динаміки в машинобудуванні, будівельних конструкцій. Алгоритм дозволить прогнозувати напружено-деформований стан об'єкта, який знаходиться під дією тривалого або короткочасного навантаження.

Для оптимального проєктування конструкцій використовуються генетичні алгоритми, що описано в роботі (Tao S., 2019). Проте дане дослідження враховує автоматизацію тільки в галузі будівництва. Робота (Mengchu Song, 2023) пропонує метод розв'язання нелінійних крайових задач в звичайних диференціальних рівняннях другого порядку, який використовує генетичні алгоритми для отримання оптимальних значень параметрів наближених розв'язань. Однак, його практичне використання пов'язане з емпіричним підбором деяких параметрів та великою кількістю ітерацій, щоб отримати прийнятний результат.

Автори роботи (Amorim L., 2020; Chen Xu, 2023) пропонують підхід, в якому нейронні мережі, а саме генетичний алгоритм та структура ансамблю поєднуються в одну популяцію. Для цього створюється набір нейронних мереж з великим ступенем різноманітності, та різні набори навчальних даних для кожної моделі. Також, генетичний алгоритм використаний для вибору ефективної підмножини синтезованих нейронних мереж, та оптимальної комбінаційної стратегії для забезпечення точності та надійності

ансамблю. Дана схема використання генетичного алгоритму в нейронних мережах є типовою.

Мета дослідження: розробка нейронної мережі для побудови адаптивних дискретних моделей, використовуючи функціональне геометричне моделювання з генетичним алгоритмом. Це дозволить підвищити точність та якість об'єктів, збільшити часову ефективність, що в свою чергу сприяє розвитку автоматизації проектувальних робіт.

Виклад основного матеріалу. Методи генерації та оптимізації дискретних моделей форм об'єктів враховують їх геометричні характеристики при виборі положення вузлів. В результаті маємо дискретні моделі, які адаптовані до особливостей форм об'єктів. Загальна ідея побудови адаптивних дискретних моделей полягає в аналізі деякої величини, яка визначена для кожного вузла. В результаті такого аналізу формується множина елементів, яку необхідно розбити.

З точки зору розробки загального алгоритму адаптації дискретних моделей, вигідним варіантом є розбиття кожного елемента у відповідності

з деяким шаблоном. І вже потім відновлюється коректність дискретної моделі шляхом розбиття сусідніх елементів.

Початковим етапом виступає розбиття кожного трикутника на три нових шляхом додавання вузлів в середини його сторін. Кожен трикутник, у якого з розбитим є спільне ребро, розбивається на два трикутники, додаючи новий вузол в середину спільного ребра. Результатом виступають два шаблони розбиття. Дана схема дозволяє виконати рівномірне розбиття дискретних моделей на базі трикутних елементів і може бути узагальнена для тетраєдрів (Рис. 1).

Для цього, якщо у сусіднього тетраєдра з розбитим є спільне ребро, він розбивається на два елементи додаючи новий вузол в середину спільного ребра. У випадку наявності спільної грані, розбиття виконується на чотири елементи шляхом додавання нових вузлів в середини ребер, які належать спільній грані. Отже, маємо три шаблони розбиття (Рис. 2–3).




Рис. 1. Схема розбиття трикутних елементів




Рис. 2. Схема розбиття тетраєдних елементів




Рис. 3. Додаткова схема розбиття тетраєдних елементів

Загальні механізми проектування адаптивної моделі на основі генетичного алгоритму виглядають наступним чином (Рис. 4):

Даний алгоритм також може адаптивно знаходити параметри x , y , z для виконання умов побудови моделі. Відбувається еволюція від

покоління до покоління, так як популяції індивідів (параметри x , y , z) змінюються.

З огляду на те, що сьогодні існує велика кількість методів формального опису геометричних об'єктів складної форми, які описані в роботах авторів (Bulat A.F., 2022; Suchocki C., 2023),

```
vector<Individual> population(populationSize);
// Ініціалізація популяції
for (int i = 0; i < populationSize; ++i) {
    population[i] = genRandomIndividual();
    population[i].fitness = calculateFitness(population[i]);
}
for (int gen = 0; gen < generations; ++gen) {
    // Сортування
    sort(population.begin(), population.end(), [](Individual a, Individual b) {
        return a.fitness > b.fitness;
    });
    // Виведення найкращого індивіда
    cout << "Generation " << gen << " Best fitness: " << population[0].fitness
        << " (x: " << population[0].x << ", y: " << population[0].y << ", z: " << population[0].z
    << endl;
    // mutation
    vector<Individual> newPopulation;
    for (int i = 0; i < populationSize / 2; ++i) {
        Individual parent1 = population[i];
        Individual parent2 = population[i + 1];
        Individual child = crossover(parent1, parent2);
        mutate(child, mutationRate);
        child.fitness = calculateFitness(child);
        newPopulation.push_back(child);
    }

    // Додавання із попереднього покоління
    for (int i = 0; i < populationSize / 2; ++i) {
        newPopulation.push_back(population[i]);
    }

    population = newPopulation;

    // Адаптація параметрів моделі
    adaptModelParams();
}
```

Рис. 4. Узагальнений програмний код генетичного алгоритму

а саме: каркасне моделювання, твердотільне геометричне моделювання. Одним з найбільш універсальних та ефективних методів є функціональний підхід. В основі даного підходу застосовується ідея використання неявних функцій разом з R-функціями В. Л. Рвачова для проєкування складних форм.

Для ефективного проведення обчислювального експерименту, візуалізуємо функціонально модель «Атом». Її можна описати наступним чином:

$$G_1(x, y, z) = 10(\sqrt{x^2 + z^2} - x^2 - y^2 - z^2) - 24,$$

$$G_2(x, y, z) = 10(\sqrt{y^2 + z^2} - x^2 - y^2 - z^2) - 24,$$

$$G_3(x, y, z) = 10(\sqrt{x^2 + y^2} - x^2 - y^2 - z^2) - 24,$$

$$G_4(x, y, z) = 9 - x^2 - y^2 - z^2,$$

$$G_5(x, y, z) = q_1(x, y, z) + q_2(x, y, z) + \sqrt{q_1(x, y, z)^2 + q_2(x, y, z)^2},$$

$$\begin{aligned} G_6(x, y, z) &= q_3(x, y, z) + q_5(x, y, z) + \\ &+ \sqrt{q_3(x, y, z)^2 + q_5(x, y, z)^2}, \\ P_9 &= q_4(x, y, z) + q_6(x, y, z) + \\ &+ \sqrt{q_4(x, y, z)^2 + q_6(x, y, z)^2}. \end{aligned} \quad (1)$$

Проєкована модель в послідовній побудові та з використанням нейронних мереж виглядає наступним чином (Рис. 5):

Як видно з рисунку, моделі за точністю майже не відрізняються, проте за часовою ефективністю модель відображається швидше (Рис. 6).

Потрібно зважати на той факт, що при збільшених значеннях параметру n , візуалізація воксельної моделі вимагатиме більших часових витрат, а також дещо збільшений обсяг пам'яті, тому дана порівняльна характеристика показує часову ефективність зі зміною параметру розбиття моделі.




Рис. 5. Візуалізація моделі: а – звичайна дискретна модель; б – дискретна модель із використанням нейронних мереж




Рис. 6. Порівняння ефективності методу

А отже, можна вважати, що даний підхід є ефективним у візуалізації дискретних об'єктів та може бути використаний в автоматизації проєктувальних робіт.

Висновки. Використання нейронних мереж, їх підходів в проєктуванні дискретних моделей складної форми недостатньо розвинуто та розповсюджено, не дивлячись на те, що сьогодні методи нейронних мереж розвиваються достатньо швидко, підкреслюючи їх ефективність.

Нейромережеві методи відкривають нові можливості, особливо для автоматизації проєктувальних робіт, найбільш точно враховуючи

реальні властивості об'єкту, в тому числі і в неявних функціях. Результати, які будуть наближені до реальних моделей досягаються за допомогою навчання на основі вибірки прикладів експериментальних даних. Що допомагає встановити прямий зв'язок «вхідних» та «вихідних» параметрів. Враховуючи результати дослідження можна зробити висновок, що застосування нейронних мереж в геометричному моделюванні є перспективним напрямом, який можна сумістити з чисельними методами (скінченні чи граничні елементи, для аналізу напружень, потоку чи інших фізичних процесів).

ЛІТЕРАТУРА:

- 1, Abambres M., Marcy M., Doz G. Potential of Neural Networks for Structural Damage Localization. *ACI Avances En Ciencias E Ingenierías*. 2018. 11, 2, 124–153. DOI: <https://doi.org/10.31224/osf.io/rghpf>
- 2, Jin C., Jang, S., Sun, X. et. al. Damage Detection of a Highway Bridge under Severe Temperature Changes Using Extended Kalman Filter Trained Neural Network. *Journal of Civil Structural Health Monitoring*. 2016. 6, 3, 545–560.
- 3, 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. 30, 3, 1–11.
- 4, Li K., Liu W., Zhao K., Shao M., Liu L. A Novel Dynamic Weight Neural Network Ensemble Model. *International Journal of Distributed Sensor Networks*. 2015. 11, Article ID 862056, 13 p. DOI: <https://doi.org/10.1155/2015/862056>
- 5, Tao S. Deep Neural Network Ensembles. 2019. Retrieved from: <https://arxiv.org/abs/1904.05488>
- 6, Mengchu Song, Xinxin Zhang, Morten Lind. Automatic identification of maintenance significant items in reliability centered maintenance analysis by using functional modeling and reasoning. *Computers & Industrial Engineering*. 2023. Volume 182. P. 1–9
- 7, Amorim L., Goveia T., Mesquita R., Baratta I. J. Microwaves. GPU Finite Element Method Computation Strategy Without Mesh Coloring. *Optoelectronics and Electromagnetic Applications*. 2020. Vol. 19. No. 2. P. 252–264.
- 8, Chen Xu, Ba Trung Cao, Yong Yuan, Günther Meschke. Transfer learning based physics-informed neural networks for solving inverse problems in engineering structures under different loading scenarios. *Computer Methods in Applied Mechanics and Engineering*. 2023. Volume 405.
- 9, Bulat A. F., Dyrda V. I., Grebenyuk S. M., Klymenko M. I. Numerical Simulation of Viscoelastic Deformation of Rubber Shock Absorbers Based on the Exponential Law. *Strength of Materials*. 2022. № 54(5). P. 776–784.
- 10, Suchocki C., Jemioło S. On Finite Element Implementation of Polyconvex Incompressible Hyperelasticity: Theory, Coding and Applications. *Int. J. of Computational Methods*. 2020. Vol. 17. No 8. 1950049.
- 11, Zhou H., Pu J., Chen, Y. Data-driven forward-inverse problems for the variable coefficients Hirota equation using deep learning method. *Nonlinear Dyn* 111, 2023. 14667–14693. <https://doi.org/10.1007/s11071-023-08641-1>
- 12, Ming Z., Zhenya Y. Data-driven forward and inverse problems for chaotic and hyperchaotic dynamic systems based on two machine learning architectures, *Physica D: Nonlinear Phenomena*, 2023. Volume 446, 133656, <https://doi.org/10.1016/j.physd.2023.133656>

REFERENCES:

1. Abambres, M., Marcy, M., & Doz, G. (2018). Potential of Neural Networks for Structural Damage Localization. *ACI Avances En Ciencias E Ingenierías*. 11, 2, 124–153. DOI: <https://doi.org/10.31224/osf.io/rghpf>
2. Jin, C., Jang, S., & Sun, X. et. al. (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, 3, 545–560.
3. 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.

4. Li, K., Liu, W., Zhao, K., Shao, M., & Liu, L. (2015). A Novel Dynamic Weight Neural Network Ensemble Model. *International Journal of Distributed Sensor Networks*. 11, Article ID 862056, 13 p. DOI: <https://doi.org/10.1155/2015/862056>
5. Tao, S. Deep Neural Network Ensembles. Retrieved from: <https://arxiv.org/abs/1904.05488>
6. Mengchu, Song, Xinxin, Zhang, Morten, Lind (2023). Automatic identification of maintenance significant items in reliability centered maintenance analysis by using functional modeling and reasoning. *Computers & Industrial Engineering*. Volume 182. P. 1–19.
7. Amorim, L., Goveia, T., Mesquita, R., Baratta, I.J. Microwaves (2020). GPU Finite Element Method Computation Strategy Without Mesh Coloring. *Optoelectronics and Electromagnetic Applications*. Vol. 19. No. 2. P. 252–264.
8. Chen, Xu, Ba Trung, Cao, Yong, Yuan, Günther, Meschke. (2023). Transfer learning based physics-informed neural networks for solving inverse problems in engineering structures under different loading scenarios. *Computer Methods in Applied Mechanics and Engineering*. Volume 405.
9. Bulat, A.F., Dyrda, V.I., Grebenyuk, S.M., Klymenko, M.I. (2022). Numerical Simulation of Viscoelastic Deformation of Rubber Shock Absorbers Based on the Exponential Law. *Strength of Materials*. № 54(5). P. 776–784.
10. Suchocki, C., Jemioło, S. (2020). On Finite Element Implementation of Polyconvex Incompressible Hyperelasticity: Theory, Coding and Applications. *Int. J. of Computational Methods*. Vol. 17. No 8. 1950049.
11. Zhou, H., Pu, J. & Chen, Y. (2023). Data-driven forward–inverse problems for the variable coefficients Hirota equation using deep learning method. *Nonlinear Dyn* 111, 14667–14693. <https://doi.org/10.1007/s11071-023-08641-1>
12. Ming, Z., Zhenya, Y. (2023). Data-driven forward and inverse problems for chaotic and hyperchaotic dynamic systems based on two machine learning architectures, *Physica D: Nonlinear Phenomena*, Volume 446, 133656, <https://doi.org/10.1016/j.physd.2023.133656>