

Національний технічний університет України
«Київський політехнічний інститут імені Ігоря Сікорського»
Міністерство освіти і науки України

Національний технічний університет України
«Київський політехнічний інститут імені Ігоря Сікорського»
Міністерство освіти і науки України

Кваліфікаційна наукова
праця на правах рукопису

МОМОТ АНДРІЙ СЕРГІЙОВИЧ

УДК 620.179.1:004.032.26

ДИСЕРТАЦІЯ
УДОСКОНАЛЕННЯ МЕТОДУ ВИЗНАЧЕННЯ ХАРАКТЕРИСТИК
ДЕФЕКТІВ БАГАТОШАРОВИХ МАТЕРІАЛІВ ЗА РЕЗУЛЬТАТАМИ
АКТИВНОГО ТЕПЛОВОГО КОНТРОЛЮ

151 Автоматизація та комп'ютерно-інтегровані технології
Автоматизація та приладобудування

Подається на здобуття наукового ступеня доктора філософії

Дисертація містить результати власних досліджень. Використання ідей,
результатів і текстів інших авторів мають посилання на відповідне джерело

_____ А. С. Момот

Науковий керівник

Галаган Роман Михайлович, кандидат технічних наук, доцент

Київ - 2020

АНОТАЦІЯ

Момот А. С. Удосконалення методу визначення характеристик дефектів багат шарових матеріалів за результатами активного теплового контролю. – Кваліфікаційна наукова праця на правах рукопису.

Дисертація на здобуття наукового ступеня доктора філософії за спеціальністю 151 «Автоматизація та комп'ютерно-інтегровані технології». – Національний технічний університет України «Київський політехнічний інститут імені Ігоря Сікорського», Київ, 2020.

В дисертації вперше отримані такі нові наукові результати:

1. Запропоновано метод автоматизованої обробки послідовності термограм, отриманих у результаті активного теплового контролю багат шарових матеріалів, який використовує нейромережеві технології для аналізу температурних профілів у кожній точці об'єкту та дозволяє одночасно проводити класифікацію знайдених дефектів, вимірювати їх глибину залягання та розкрити.

2. Набув подальшого розвитку метод синтезу нейронної мережі прямого розповсюдження зі зворотним поширенням помилки, який враховує залежності достовірності контролю та точності дефектометрії від архітектури та алгоритмів навчання нейронної мережі, що дозволило обґрунтувати вибір кількості прихованих прошарків нейронної мережі, кількості нейронів у цих прошарках та оптимального за показником середньоквадратичної помилки мережі алгоритму навчання.

3. Удосконалено метод формування навчального набору даних, який враховує залежності достовірності класифікації дефектів у багат шарових матеріалах, похибок визначення їх глибини залягання і розкрити від параметрів вибірки навчальних сигналів, що дозволило мінімізувати час навчання нейронної мережі без погіршення достовірності автоматизованої класифікації дефектів та точності дефектометрії.

Практичне значення одержаних в дисертаційній роботі результатів полягає в тому, що було розроблено алгоритмічне і програмне забезпечення реалізації підсистеми визначення характеристик дефектів за результатами активного ТНК із використанням вдосконаленого методу на базі нейромережових технологій, що дозволило автоматизувати класифікацію дефектів і побудову теплових томограм, підвищити точність теплової дефектометрії і достовірність контролю у порівнянні з існуючими методами. Розроблено віртуальний інтерфейс користувача, який містить інструменти для проведення дефектометрії та аналізу теплових томограм, що дало змогу покращити ефективність аналізу результатів контролю. Для розробленої системи експериментально визначено архітектуру та параметри навчання нейромереж, за яких досягається найвища достовірність класифікації дефектів та точність вимірювання їх характеристик. Розроблено та виготовлено експериментальний стенд та дослідні зразки для проведення активного теплового контролю і аналізу результатів із використанням удосконаленого методу визначення характеристик дефектів на основі нейронних мереж, що дозволило відпрацювати програмні алгоритми та підтвердити ефективність даного методу.

У дисертаційній роботі описано особливості та проблеми теплового контролю виробів із багатошарових матеріалів. Показано, що на сучасному етапі розвитку методів теплового неруйнівного контролю важливим завданням є не лише виявлення та визначення координат і поперечних розмірів дефектів багатошарових матеріалів, але і вимірювання їх глибини залягання та розкриву. Проведено аналіз факторів, які впливають на результати теплового контролю та описано характер взаємозв'язків між інформативними параметрами. Розглянуто традиційні математичні та статистичні методи теплової дефектометрії та встановлено їх недоліки. Описано, що аналітичний розв'язок обернених задач теплового контролю в ряді випадків є неоднозначним. Особливо низьку ефективність традиційні методи та побудовані на їх основі системи теплової дефектометрії мають у випадку контролю багатошарових матеріалів.

В роботі проведено порівняльний аналіз стандартних та спеціальних методів цифрової обробки термограм. Розглянуто методи Фур'є-аналізу, вейвлет-аналізу,

аналізу головних компонент та динамічної теплової томографії. Показано, що дані методи мають низьку завадостійкість, сильну залежність результатів від вибору опорної точки та рівномірності нагріву об'єкту контролю. Окрім того, розглянуті традиційні методи обробки термограм не дозволяють проводити автоматичну класифікацію дефектів за типом та визначати їх розкриття.

У дисертаційній роботі описано можливості використання штучних нейронних мереж для удосконалення методів визначення характеристик дефектів. Розглянуто особливості побудови нейромережових систем для вирішення задач класифікації дефектів та визначення їх глибини залягання і розкриття. Проведено порівняння ефективності роботи нейронних мереж та традиційних методів обробки термограм. Показано переваги нейронних мереж над традиційними алгоритмами.

Розглянуто найбільш перспективні області застосування нейромережових систем аналізу результатів активного теплового неруйнівного контролю. Проведено аналіз існуючих робіт за напрямом теплового контролю композитів. Показано, що у відомій літературі не вирішуються завдання одночасної класифікації дефектів за типом та визначення їх глибини залягання і розкриття; не досліджено способи визначення глибини залягання дефектів або їх розкриття шляхом вирішення задачі регресії за допомогою нейронних мереж; не вирішується завдання побудови теплових зображень внутрішньої структури об'єкту контролю. Сформовано мету дослідження у вигляді автоматизації процесу активної теплової дефектоскопії та дефектометрії із застосуванням нейромережових технологій, що забезпечуватиме підвищення інформативності, достовірності та ефективності контролю виробів із багатошарових матеріалів.

З метою удосконалення методів активної теплової дефектоскопії і дефектометрії та автоматизації обробки даних в дисертації обґрунтовано та розроблено підсистему цифрової обробки термограм, що складається з трьох нейромережових модулів. Описано можливість використання багатошарових нейронних мереж прямого розповсюдження зі зворотним поширенням помилки з повнозв'язними прошарками у складі модуля виявлення та класифікації дефектів та модулів визначення глибини залягання і розкриття дефектів.

Сформовано алгоритми формування навчальних множин для задач класифікації дефектів та визначення їх глибини залягання і розкриття. Описано процедуру навчання нейромережових модулів та розроблено відповідне програмне забезпечення в середовищі MATLAB. Виконано програмну реалізацію віртуальних приладів в середовищі NI LabVIEW, в яких втілено алгоритми роботи нейромережових модулів та пост-обробки результатів. Створено графічний інтерфейс користувача, який містить елементи керування, інструменти для проведення дефектометрії та блоки графічного відображення інформації щодо положення дефектів та внутрішньої структури об'єкту контролю.

На основі проведеного комп'ютерного моделювання процесу активного теплового контролю алюмінієвої пластини зі штучними внутрішніми дефектами отримано послідовності термограм. Встановлено, що внаслідок впливу високого рівня теплової дифузії та нерівномірності нагріву обробка отриманих послідовностей термограм традиційними методами є ускладненою та малоефективною. В результаті досліджень доведено, що розроблена автоматизована нейромережева система має покращені якісні та кількісні показники ефективності у порівнянні з традиційними методами.

У роботі проведено комп'ютерне моделювання процесу активного теплового контролю зразка із багатошарового вуглепластику зі штучними внутрішніми дефектами. За результатами досліджень ефективності обробки отриманих послідовностей термограм різними методами встановлено, що розроблена нейромережева система забезпечує найвищі показники якості класифікації дефектів та точності дефектометрії серед розглянутих методів.

Досліджено вплив архітектури нейронних мереж на результати роботи нейромережових модулів розробленої системи у випадку обробки даних комп'ютерного моделювання. Дослідження показали, що найбільш оптимальним є використання двох прихованих прошарків з 12 нейронами в першому та 4 нейронами в другому прошарках. Встановлено, що із доступних алгоритмів навчання найбільш ефективним за показником середньоквадратичної помилки мережі є оптимізатор Левенберга-Маркарда.

Проведено дослідження впливу обсягу та якості навчальної вибірки на результати роботи нейромережових модулів. Встановлено кількісні значення погіршення показників ефективності роботи системи. У випадку зменшення кількості навчальних зразків в чотири рази, на 7,55 % знижується значення критерію Танімото та на 14,74 % зростає відносна похибка визначення глибини залягання дефектів. Водночас, в чотири рази зменшується час навчання. Аналогічні результати отримано і для випадку зменшення репрезентативності вибірки.

Розроблено та виготовлено 2 тестових та 5 навчальних зразків у вигляді пластин із багатошарових композиційних матеріалів, які містять штучні внутрішні дефекти з відомими параметрами. Зразки використовувались для проведення експериментальних досліджень ефективності роботи розробленої автоматизованої системи. Для проведення експериментів було виготовлено стенд для проведення активного теплового контролю за схемою з двостороннім доступом до об'єкту.

За результатами експериментальних досліджень встановлено, що в реальних умовах архітектура нейронних мереж відповідних модулів має бути ускладнена до 35 нейронів в першому та 15 нейронів в другому прихованому прошарках. Дослідження показали, що розроблена система дозволяє проводити безпомилкове виявлення та класифікацію дефектів за типом. Оцінка глибини залягання та розкриття дефектів із використанням розробленої системи відбувається з максимальною похибкою $\pm 3,19\%$ та $3,50\%$ відповідно. Доведено, що розроблена система має підвищену достовірність контролю та точність дефектометрії у порівнянні з традиційними алгоритмами навіть в умовах нерівномірного нагріву. На основі результатів досліджень сформульовано рекомендації щодо методики контролю із використанням розробленої автоматизованої системи.

Ключові слова: неруйнівний контроль, тепловий контроль, тепла дефектометрія, тепла томографія, теплове поле, композиційні матеріали, нейронні мережі, нейромережовий класифікатор, мережа прямого розповсюдження, зворотне поширення помилки, машинне навчання.

SUMMARY

Momot A. Improvement of the method for defining defects characteristics of multilayered materials by active thermal testing. – Qualifying scientific work, the manuscript.

Thesis for a PhD degree in specialty 151 "Automation and Computer-Integrated Technologies". – National Technical University of Ukraine "Igor Sikorsky Kyiv Polytechnic Institute", Kyiv, 2020.

In the dissertation the following new scientific results were first received:

1. The method of automated processing of thermograms sequences in active thermal testing of multilayer materials is proposed, which uses neural networks to analyze the temperature profiles at each point of the object and allows to simultaneously classify the founded defects, measure their depth and thickness.

2. The method of feedforward backpropagation neural network synthesis, which takes into account dependencies of reliability of testing and accuracy of defectometry on architecture and algorithms neural network training, has been further developed. This made it possible to justify the choice of the number of hidden layers of the neural network, the number of neurons in these layers, and the optimal by mean squared error indicator training algorithm.

3. The method of forming a training dataset has been developed, which takes into account dependencies of defect classification reliability in multilayered materials, errors of determining their depth and thickness from the parameters of the training signals sampling, which allowed to minimize learning time of neural network without impairing the reliability of automated defects classification.

The significance of practical thesis results are that the algorithmic and software implementation of defect characterization subsystem based on the results of active thermal nondestructive testing were developed using an improved neural network-based method, which made it possible to automate the classification of defects and construct

thermal tomograms. and increase the reliability of testing compared to existing methods. A virtual user interface has been developed that includes tools for defectometry and thermal tomography analysis, which made it possible to improve the efficiency of analysis of control results. For the developed subsystem, the architecture and parameters of neural networks training were experimentally determined, at which the highest accuracy of defect classification and precision of measuring their characteristics were achieved. An experimental stand and prototypes for active thermal testing and analysis of its results were developed and manufactured using an improved neural network method, which allowed to work out software algorithms and confirm the effectiveness of this advanced method of defect characterization.

The thesis describes that in the present stage of methods of thermal non-destructive testing development important task is not only to identify and determine the coordinates and transverse dimensions of defects, but also to measure their depth and thickness. The factors that influence on results of thermal testing are analyzed and the nature of relationship between informative parameters is described. Traditional mathematical and statistical methods of thermal defectometry are considered and their disadvantages are established. It has been described that the analytical solution of inverse thermal testing tasks is ambiguous in some cases. Particularly low efficiency traditional methods and thermal defectometry systems based on them have in the case of multilayer materials testing.

The comparative analysis of standard and special digital processing of thermograms methods is carried out in the work. The methods of Fourier analysis, wavelet analysis, principal component analysis and dynamic thermal tomography are considered. As have been shown, these methods have low noise immunity, a strong dependence of results on the choice of anchor point and a uniform heating of the object of testing. In addition, considered traditional methods of thermogram processing do not allow the automatic classification of defects by type and to determine their thickness.

The thesis describes the possibilities of using artificial neural networks for improvement of defect characterization methods. Features of construction the neural network systems for solving tasks of defects classification and their depth and thickness

determination are considered. The performance of neural networks and traditional methods of thermogram processing are compared. Advantages of neural networks over traditional algorithms are shown.

The most promising areas of application of neural network systems of analysis of active thermal non-destructive testing results are considered. Features and problems of thermal testing of products made of multilayer composite materials are described. Analysis of existing works in the field of thermal defectometry of composites, in particular, using neural networks, is done in this thesis. It is shown that in known literature the tasks of simultaneous defects classification by type and determination of their depth and thickness are not solved; the methods of determining defects depth or their thickness by solving the regression task using neural networks or traditional methods have not been investigated; the task of constructing thermal tomograms of object of testing internal structure is not solved. Research aim in the form of development of a neural network automated system of thermal fields complex analysis, which will have higher efficiency in comparison with systems based on traditional methods of thermogram processing is formed in this thesis.

In order to improve the methods of thermal defectoscopy and defectometry and automate data processing, a subsystem of digital thermogram processing consisting of three neural network modules has been substantiated and developed in the thesis. Possibility of using feedforward backpropagation multilayer neural networks with fully-connected layers in defects detection and classification module and modules of determining defects depth and thickness is described.

Algorithms of formation of training datasets for tasks of defects classification and determination of their depth and thickness are formed. The procedure of neural network modules training is described and the corresponding software is developed in MATLAB. Software implementation of virtual devices, which embodies algorithms of neural network modules and results post-processing is implemented in NI LabVIEW software. A graphical user interface for an automated thermal field analysis system has been created. That includes controls, defectometry tools and blocks for graphically displaying information about defects location and the internal structure of object of testing.

Based on computer simulations of the process of active thermal testing of an aluminum plate with artificial internal defects, thermogram sequences were obtained. It is established that due to influence of high level of thermal diffusion and uneven heating, processing of the obtained thermogram sequences by traditional methods is complicated and ineffective. As a result of research, it is proved that the developed automated neural network system has improved qualitative and quantitative indicators of efficiency in comparison with traditional methods.

The computer simulation of the process of active thermal testing of a multilayer carbon fiber specimen with artificial internal defects is carried out. According to results of efficiency evaluation of obtained thermogram sequences processing by different methods, it is established that the developed neural network system provides the highest indicators of quality of defect classification and defectometry accuracy among considered methods.

The influence of neural network architecture on performance of neural network modules of developed system in case of computer simulation data is investigated. Studies have shown that the most optimal use is two hidden layers with 12 neurons in the first and 4 neurons in the second layer. It is established that the Levenberg-Markard optimizer is the most effective of the available learning algorithms in terms of networks mean squared error.

The influence of volume and quality of the training dataset on the results of neural network modules work has been investigated. Quantitative values of deterioration of system performance indicators were established. If the number of training samples is reduced by four times, the value of Tanimoto criterion is reduced by 7.55 % and relative error of defects depth estimation is increased by 14.74 %. At the same time, training time is reduced four times. Similar results were obtained for the case of a decrease in dataset representativeness.

During the work, 2 test and 5 training specimens in form of multilayer composite plates containing artificial defects with known parameters were developed and manufactured. The samples were used for experimental researches of developed

automated system performance. An appropriate stand was made for the experiments to conduct active thermal testing using double-access testing scheme.

According to the results of experimental researches, it was found that in real-world conditions, the architecture of neural networks of respective modules should be complicated up to 35 neurons in the first and 15 neurons in the second hidden layers. Researches have shown that developed system allows to carry out error-free detection and classification of defects by type. Estimation of defects depth and thickness using developed system was conducted with the maximum error of $\pm 3.19\%$ and 3.50% respectively. It is proved that developed system has higher reliability of testing and accuracy of defectometry in comparison with traditional algorithms even in conditions of uneven heating. Based on the results of research, recommendations on methodology of testing using developed automated system are formulated.

Keywords: nondestructive testing, thermal testing, thermal defectometry, thermal tomography, thermal field, composite materials, neural networks, neural network classifier, feedforward network, backpropagation of error, machine learning.

Список публікацій здобувача:

1. Момот А.С. Реалізація нейромережових алгоритмів класифікації технічного стану композиційних матеріалів за результатами акустичного контролю / А. С. Момот, Р. М. Галаган. // Техническая диагностика и неразрушающий контроль. – 2017. – №1. – С. 43–46.

Здобувачем розроблено нейромережову систему класифікації технічного стану композиційних матеріалів, обґрунтовано ефективність застосування нейронних мереж в якості систем підтримки прийняття рішень у неруйнівному контролі.

2. Момот А.С. Аналіз методів цифрової обробки термограм / А. С. Момот, Р. М. Галаган. // Вісник Національного технічного університету України "Київський політехнічний інститут". Серія приладобудування. – 2018. – №55. – С. 108–117. (Входить до WorldCat, РИНЦ, Index Copernicus, BASE, OpenAIRE та інших)

Здобувачем проведено аналітичний огляд існуючих методів цифрової обробки термограм, встановлено переваги використання нейронних мереж перед традиційними методами

3. Momot A. S. Analysis of application of neural networks to improve the reliability of active thermal NDT / A. S. Momot, R. M. Galagan. // KPI Science News. – 2019. – №1. – pp. 7–14. (Входить до WorldCat, Index Copernicus, BASE, OpenAIRE та інших)

Здобувачем проведено комп'ютерне моделювання активного теплового контролю сталеві пластини та обґрунтовано можливість підвищення достовірності контролю із застосуванням нейронних мереж.

4. Momot A. S. Statistical analysis of thermal nondestructive testing data / A. S. Momot, R. M. Galagan. // Advanced Information Systems. – Kharkiv. – 2019. – №3. – pp. 58–62.

Здобувачем проведено кореляційний, регресійний та дисперсійний аналіз взаємозв'язків між інформативними параметрами теплового контролю.

5. Momot A. Influence of architecture and training dataset parameters on the neural networks efficiency in thermal nondestructive testing / A. Momot, R. Galagan. // Sciences of Europe. – 2019. – №44. – pp. 20–25. (Входить до Index Copernicus та інших)

Здобувачем проведено формування навчальних множин вхідних даних з різними характеристиками, навчено моделі нейронних мереж та встановлено вплив розглянутих параметрів на ефективність розробленої системи.

6. Momot A. S. The use of ART-2 neural network for processing information signals of non-destructive testing / A.S. Momot, R.M. Galagan. // proc. 2017 IEEE First Ukraine Conference on Electrical and Computer Engineering (UKRCON) Kiev, 29 May–2 June 2017 / IEEE. – 2017. – pp. 981–985.

Здобувачем обґрунтовано можливості застосування нейронних мереж для обробки інформаційних сигналів неруйнівного контролю, реалізовано та досліджено алгоритми нейронної мережі для класифікації технічного стану об'єкту.

7. Момот А.С. Застосування нейромережевих технологій для вирішення обернених задач неруйнівного контролю / А. С. Момот, Р. М. Галаган. // XVI Міжнародна науково-технічна конференція «Приладобудування: стан і перспективи», 16-17 травня 2017 р., м. Київ, Україна : збірник тез доповідей. – Київ: КПІ ім. Ігоря Сікорського, 2017. – С. 144.

Здобувачем проаналізовано сучасний стан та тенденції розвитку методів вирішення зворотних задач теплового неруйнівного контролю, обґрунтовано необхідність застосування нейронних мереж в задачах теплової дефектометрії.

8. Момот А.С. Теплова томографія із застосуванням штучних нейронних мереж / А. С. Момот, Р. М. Галаган. // XVII Міжнародна науково-технічна конференція «Приладобудування: стан і перспективи», 15-16 травня 2018 р., м. Київ, Україна : збірник тез доповідей. – Київ : КПІ ім. Ігоря Сікорського, 2018. – С. 178-179.

Здобувачем обґрунтовано можливість застосування нейронних мереж для побудови теплових томограм, проведено комп'ютерне моделювання процесу теплової дефектометрії із застосуванням нейронних мереж.

9. Momot A. S. The Use of Backpropagation Artificial Neural Networks in Thermal Tomography / A.S. Momot, R.M. Galagan. // proc. 2018 IEEE First International Conference on System Analysis & Intelligent Computing (SAIC) Kiev, 8-12 October 2018 / IEEE. – 2018. – pp. 1–6.

Здобувачем обґрунтовано доцільність використання нейронних мереж зворотного поширення помилки в задачах теплової томографії, проведено комп'ютерне моделювання процесу активного теплового контролю та побудовано теплову томограму.

10. Момот А. С. Нейромережева система теплової дефектометрії / А. С. Момот. // II науково-технічна конференція “НК в контексті асоційованого членства України в ЄС” 15-19 жовтня 2018, м. Люблін, Польща: збірник тез доповідей. – Люблін: УТ НКТД, 2018. – С. 23-26.

11. Момот А.С. Статистический анализ взаимосвязей между информативными параметрами активного теплового неразрушающего контроля /

А. С. Момот, Р. М. Галаган. // Приборостроение-2018: материалы 11-й Международной научно-технической конференции, 14-16 ноября 2018 года, Минск, Республика Беларусь. – Минск: БНТУ, 2018. – С. 139-141.

Здобувачем проведено комп'ютерне моделювання активного теплового контролю, здійснено кореляційний, регресійний та дисперсійний аналіз взаємозв'язків інформативних параметрів теплового контролю.

12. Momot A. S. Thermal defectometry of composite materials using artificial neural networks / A. S. Momot. // XVIII Міжнародна науково-технічна конференція «Приладобудування: стан і перспективи», 15-16 травня 2019 р., м. Київ, Україна: збірник тез доповідей. – Київ : КПІ ім. Ігоря Сікорського, 2019. – С. 154-155.

13. Momot, A. Defect classification in active thermal testing with the use of neural networks / A. Momot // Матеріали III науково-технічної конференції «Неруйнівний контроль в контексті асоційованого членства України в Європейському Союзі» з міжнародною участю – NDT – UA 2019, 17-19 вересня 2019 року, м. Київ, Україна. – Київ : УТ НКТД, 2019. – С. 16-18

14. Момот, А. С. Дослідження ефективності нейронних мереж в активному тепловому контролі в залежності від характеристик навчальної вибірки / А. С. Момот, Р. М. Галаган // 9-а Національна науково-технічна конференція і виставка «Неруйнівний контроль та технічна діагностика – UkrNDT-2019», 19-21 листопада 2019 р., м. Київ, Україна: збірник доповідей. – Київ : УТ НКТД, 2019. – С. 229-231.

Здобувачем проведено навчання нейронних мереж класифікації та визначення глибини залягання і розкриття дефектів, встановлено вплив обсягу та якості навчальної вибірки на результати роботи відповідних мереж.

ЗМІСТ

Анотація	2
Summary	7
Перелік умовних позначень і скорочень.....	19
Вступ.....	20
РОЗДІЛ 1. Аналіз сучасного стану та напрямів розвитку методів активного теплового контролю виробів із багат шарових матеріалів	30
1.1.Опис об’єкта та обґрунтування методу контролю	30
1.1.1. Актуальність удосконалення методів контролю виробів із композиційних матеріалів	32
1.1.2. Огляд методів неруйнівного контролю композиційних матеріалів	33
1.1.3. Фізичні принципи активного теплового неруйнівного контролю... ..	35
1.1.4. Особливості теплового контролю багат шарових матеріалів	40
1.2.Аналіз традиційних методів обробки термограм	41
1.2.1. Фур’є-аналіз.....	42
1.2.2. Вейвлет-аналіз.....	44
1.2.3. Метод аналізу головних компонент.....	46
1.2.4. Динамічна тепла томографія.....	48
1.3.Застосування нейронних мереж в тепловій дефектометрії	50
1.3.1. Обґрунтування можливості застосування нейронних мереж для обробки послідовностей термограм.....	50
1.3.2. Опис основних принципів роботи нейромережових систем	51
1.3.3. Модель штучного нейрона.....	53
1.3.4. Багат шарова нейронна мережа	54
1.3.5. Принципи навчання нейронних мереж.....	55

1.3.6. Оцінка ефективності застосування нейронних мереж у порівнянні з традиційними методами	57
1.4.Огляд існуючих робіт за напрямом дослідження	60
1.5.Постановка мети та задач дослідження	63
Висновки до розділу 1	64
РОЗДІЛ 2. Розробка методу автоматизованої обробки послідовності термограм із використанням нейромережових технологій	66
2.1. Реалізація удосконаленого методу визначення характеристик дефектів за результатами активного теплового контролю	66
2.2. Вибір типу та архітектури нейромережових модулів	68
2.2.1. Аналіз типів нейронних мереж, що можуть бути застосовані для обробки даних теплового контролю	69
2.2.2. Обґрунтування вибору багатосарової мережі прямого розповсюдження зі зворотним поширенням помилки	72
2.2.3. Вибір архітектури обраної нейронної мережі	74
2.3. Розробка алгоритмів формування навчальної множини вхідних векторів.....	75
2.3.1. Алгоритм формування навчальної множини для класифікації дефектів.....	77
2.3.2. Алгоритм формування навчальної множини для визначення глибини залягання та розкриву дефектів.....	80
2.4. Розробка віртуальних приладів для реалізації системи аналізу даних теплового контролю із використанням удосконаленого методу визначення характеристик дефектів	81
2.4.1. Вибір програмного забезпечення для розробки віртуальних приладів.....	81

2.4.2. Розробка блок-діаграми віртуальних приладів для реалізації нейромережових модулів	83
2.4.3. Розробка блок-діаграм для реалізації пост-обробки відповідей нейромережових модулів	89
2.4.4. Розробка інтерфейсу користувача системи аналізу даних теплового контролю із використанням удосконаленого методу визначення характеристик дефектів	95
Висновки до розділу 2	100
РОЗДІЛ 3. Обробка результатів комп'ютерного моделювання процесу активного теплового контролю із використанням удосконаленого методу визначення характеристик дефектів.....	102
3.1. Програмне забезпечення для створення комп'ютерної моделі процесу активного теплового контролю	102
3.2. Комп'ютерне моделювання процесу активного теплового контролю зразка з багатошарового композиційного матеріалу.....	103
3.2.1. Створення комп'ютерної моделі зразка та опис експерименту	104
3.2.2. Обробка результатів моделювання традиційними методами	108
3.2.3. Формування навчального набору даних для нейромережових модулів	114
3.2.4. Обробка результатів комп'ютерного моделювання з використанням удосконаленого методу визначення характеристик дефектів	117
3.2.5. Оцінка та аналіз результатів моделювання	121
3.3. Дослідження впливу архітектури нейронних мереж, параметрів навчання та характеристик навчальної вибірки на результативність системи	123
3.3.1. Дослідження впливу кількості прихованих прошарків та кількості нейронів на результативність системи	124

	18
3.3.2. Дослідження впливу алгоритмів навчання на характеристики нейронних мереж	128
3.3.3. Дослідження впливу обсягу та якості навчальної вибірки на результати роботи системи	131
3.3.4. Дослідження впливу кількості термограм у початковій послідовності на результативність системи	135
Висновки до розділу 3	137
РОЗДІЛ 4. Експериментальні дослідження ефективності автоматизованої класифікації дефектів та дефектометрії удосконаленим методом.....	141
4.1. Дослідження зразків з багатошарового склотекстоліту	142
4.1.1. Розробка та виготовлення експериментальних зразків	142
4.1.2. Опис експерименту	143
4.1.3. Обробка експериментальних даних традиційними методами	147
4.1.4. Формування навчального набору експериментальних даних для нейромережових модулів	152
4.1.5. Обробка експериментальних даних із використанням розробленої нейромережової системи	154
4.1.6. Аналіз та оцінка результатів експерименту	159
4.2. Рекомендації щодо проведення контролю із використанням розробленої системи аналізу даних	160
Висновки до розділу 4	164
Висновки	166
Список використаних джерел	170
Додаток А.....	185
Додаток Б	187
Додаток В	188

ПЕРЕЛІК УМОВНИХ ПОЗНАЧЕНЬ І СКОРОЧЕНЬ

АТНК	–	активний тепловий неруйнівний контроль;
НК	–	неруйнівний контроль;
ОК	–	об'єкт контролю;
КМ	–	композиційні матеріали;
НМ	–	нейронна мережа;
ТНК	–	тепловий неруйнівний контроль;
ОЗ	–	обернена задача;
ПЗ	–	програмне забезпечення;
ПК	–	персональний комп'ютер;
ДТТ	–	динамічна теплова томографія;
МАГК	–	метод аналізу головних компонент;
СКВ	–	середньоквадратичне відхилення;
АРТ	–	адаптивна резонансна теорія;
ЗНМ	–	згорткова нейронна мережа;
ВП	–	віртуальний прилад;
FEM	–	метод кінцеворозмірних елементів;
MSE	–	середньоквадратична помилка;

ВСТУП

Обґрунтування вибору теми дослідження.

Методи теплового неруйнівного контролю на сучасному етапі розвитку дозволяють виявляти приховані дефекти (дефектоскопія) та визначати їх розміри (дефектометрія). ТНК застосовується для контролю якості широкого спектру виробів з внутрішніми технологічними дефектами у вигляді тріщин, розшарувань і сторонніх включень. Особливу цікавість завдяки ряду переваг викликає активний ТНК, застосування якого дозволяє значно розширити перелік можливих ОК. Серед таких об'єктів можна окремо виділили багатошарові та композиційні матеріали, контроль яких іншими методами є ускладненим. Від наявності дефектів, їх розмірів та локалізації залежить надійність та працездатність елементів конструкцій в умовах експлуатаційних навантажень. Тому проблема виявлення дефектів і визначення їх параметрів має велике теоретичне і практичне значення.

На сьогоднішній день задачі виявлення дефектів методами та засобами неруйнівного контролю вирішені майже в повному обсязі. Проте споживача в першу чергу цікавить рівень небезпеки дефектів для конструкції та їх вплив на термін експлуатації. Тому важливим завданням є визначення кількісних параметрів дефектів та їх класифікації. Такі задачі відносяться до класу обернених, і в області ТНК на даний час залишаються одними із найважчих для вирішення. Особливо помітною ця проблема є у випадку контролю виробів із багатошарових матеріалів.

Сучасні методи розробки математичних моделей можна застосовувати лише для часткового вирішення обернених задач ТНК. Аналітичні моделі описуються складними нелінійними залежностями, які зазвичай не дають однозначного рішення, а також потребують значних обчислювальних витрат. Тому на практиці в задачах класифікації та дефектометрії перспективним є перехід від визначення окремих кількісних характеристик дефектів до аналізу зображень фізичних полів, що створюються дефектом. Такий підхід дозволяє значно спростити та оптимізувати процес класифікації дефектів, а, отже, і вирішення обернених задач.

Якість отриманих під час контролю термограм, які відображають розподіл інтенсивності теплового поля об'єкта контролю, залежить від багатьох факторів. Теплові зображення часто містять високі за рівнем шуми та завади, а характер теплових відбитків дефектів не завжди дозволяє зробити однозначні висновки щодо їх розміру, форми, положенню, глибині залягання. У зв'язку з цим, в багатьох випадках неможливо проаналізувати технічний стан ОК, використовуючи лише один інформативний параметр – температуру. Відомо, що гістограми розподілу температур в дефектних та бездефектних областях частково перекривають одна одну, що знижує надійність прийняття рішення. З метою підвищення достовірності контролю до розгляду вводяться додаткові інформативні параметри, наприклад, оптимальний час спостереження дефекту або геометричні розміри температурної аномалії.

Характерною особливістю активного ТНК є наявність кореляції всіх інформативних параметрів між собою. Тому для покращення ефективності класифікації дефектів і точності дефектометрії має проводитись комплексний аналіз теплових полів ОК. Рішення щодо визначення типу дефекту приймається на базі аналізу багатовимірного простору нелінійно пов'язаних діагностичних ознак. В більшості випадків встановити однозначну приналежність дефекту до певного класу традиційними методами є неможливим. Тими самими факторами ускладнюється і процес точного вимірювання глибини залягання або розкриву (товщини) дефектів. Дана проблема вимагає пошуку нових сучасних методів обробки даних. Зокрема, для автоматизації розпізнавання дефектів та підвищення ефективності контролю і дефектометрії, а також побудови теплових томограм ОК пропонується застосовувати штучні нейронні мережі.

В задачах ТНК навчена нейронна мережа не тільки матиме здатність розпізнавати та класифікувати дефекти за отриманими під час контролю даними, але і зберігати інформацію про закономірності і взаємозв'язки характеристик інформаційного сигналу і стану об'єкта контролю. Вагомою особливістю також є можливість правильно класифікувати інформаційні сигнали, що відповідають потенційним дефектам, які не зустрічались під час навчання.

Нейромережа може бути ефективним інструментом теплової дефектометрії. Так, вхідними даними може служити сукупність піксельних значень з відповідних послідовностей термограм, а вихід бути виражений в глибинах залягання або значеннях розкриття дефектів. Таким чином, існує можливість створення системи аналізу температурних профілів на базі нейромережових технологій. Така система матиме можливість автоматично виявляти та класифікувати дефекти, визначати їх параметри і будувати теплові томограми ОК. Водночас важливим завданням є вибір типу, архітектури НМ та алгоритмів навчання, що будуть оптимальними для обробки температурних профілів з метою визначення параметрів дефектів.

Застосування автоматизованих систем на базі НМ дозволяє вирішувати задачі, розв'язок яких традиційними математичними або статистичними методами є ускладненим або неможливим. Водночас, ефективність роботи нейромережових систем буде залежати від параметрів використаних мереж, а не від задалегідь визначених аналітичних правил. Завдяки високій адаптивності та гнучкості подібних систем існує можливість їх застосування для обробки даних різними методами НК без докорінної зміни структури.

Актуальність роботи.

На сьогоднішній день виробництво із багатошарових і композиційних матеріалів знаходить широке застосування в різних галузях промисловості. Зокрема, в авіабудуванні все частіше використовуються листові композиційні матеріали, з яких виготовляються найбільш відповідальні елементи конструкції літаків. Водночас, спостерігається тенденція до підвищення вимог до контролю якості продукції. Своєчасне виявлення прихованих дефектів надає можливість запобігти значним матеріальним, а часом і людським втратам. Завдяки ряду переваг, в задачах контролю виробів із листових композитів використовуються методи активного ТНК. Тому, актуальним є питання удосконалення існуючих методів визначення характеристик дефектів за результатами активного ТНК, що матимуть підвищену інформативність, достовірність контролю та точність дефектометрії в умовах значних рівнів завад і складної внутрішньої будови ОК.

Зв'язок роботи з науковими програмами, планами, темами.

Дисертаційну роботу виконано на кафедрі приладів і систем неруйнівного контролю Національного технічного університету України «Київський політехнічний інститут імені Ігоря Сікорського» відповідно до ініціативної науково-дослідної роботи: «Розробка інтелектуальних систем аналізу теплових полів» (ДР №0119U103757).

Мета та завдання дослідження.

Метою роботи автоматизація процесу активної теплової дефектоскопії та дефектометрії із застосуванням нейромережових технологій, що забезпечуватиме підвищення інформативності, достовірності та ефективності контролю виробів із багат шарових матеріалів.

Для досягнення поставленої мети в дисертації вирішуються наступні завдання:

1. Проаналізувати сучасний стан розвитку методів активного теплового неруйнівного контролю, визначити основні проблеми багатопараметрового активного ТНК багат шарових матеріалів та обґрунтувати застосування нейронних мереж для їх розв'язку. Обґрунтувати вибір типу та архітектури НМ.

2. Удосконалити метод оцінки характеристик дефектів при активному тепловому контролі для забезпечення автоматизованого вирішення задач класифікації дефектів, визначення їх глибини залягання і розкриття, а також побудови теплових томограм з метою підвищення інформативності та достовірності контролю. Розробити необхідне алгоритмічне та програмне забезпечення.

3. Провести комп'ютерне моделювання процесу активного ТНК зразків матеріалів з різною структурою. Обробити отримані дані за допомогою класичних методів та удосконаленого методу на базі нейронних мереж.

4. Дослідити вплив параметрів НМ та характеристик набору вхідних даних на ефективність оцінки параметрів дефектів.

5. Розробити та виготовити дослідні зразки з багатошарових матеріалів та експериментальний стенд для проведення активного ТНК із використанням системи на основі удосконаленого методу.

6. Експериментально дослідити ефективність удосконаленого методу в задачах багатопараметрового активного ТНК виготовлених зразків. Порівняти результати обробки експериментальних даних класичними методами та удосконаленим методом із використанням НМ.

Об'єктом дослідження є процес активної теплової дефектоскопії та дефектометрії.

Предметом дослідження є методи автоматизованого розпізнавання і класифікації дефектів та дефектометрії.

Методи дослідження.

Для вирішення поставленої задачі використовувались методи неруйнівного контролю та технічної діагностики, методи розпізнавання образів, методи комп'ютерного моделювання, методи проектування та імітаційного моделювання нейронних мереж, методи обробки сигналів, методи теорії імовірності та математичної статистики; за допомогою методів імітаційного моделювання нейронних мереж та комп'ютерного моделювання розроблено програмні алгоритми та віртуальні прилади системи обробки даних теплового контролю із використанням удосконаленого методу визначення характеристик дефектів, проведено моделювання процесу активного ТНК та визначення типу, глибини залягання та розкриву виявлених дефектів тестових зразків із багатошарових композиційних матеріалів.

Наукова новизна отриманих результатів.

В дисертації вперше отримані такі нові наукові результати:

1. Запропоновано метод автоматизованої обробки послідовності термограм, отриманих у результаті активного теплового контролю багатошарових матеріалів,

який використовує нейромережеві технології для аналізу температурних профілів у кожній точці об'єкту та дозволяє одночасно проводити класифікацію знайдених дефектів, вимірювати їх глибину залягання та розкрити.

2. Набув подальшого розвитку метод синтезу нейронної мережі прямого розповсюдження зі зворотним поширенням помилки, який враховує залежності достовірності контролю та точності дефектометрії від архітектури та алгоритмів навчання нейронної мережі, що дозволило обґрунтувати вибір кількості прихованих прошарків нейронної мережі, кількості нейронів у цих прошарках та оптимального за показником середньоквадратичної помилки мережі алгоритму навчання.

3. Удосконалено метод формування навчального набору даних, який враховує залежності достовірності класифікації дефектів у багатошарових матеріалах, похибок визначення їх глибини залягання і розкриття від параметрів вибірки навчальних сигналів, що дозволило мінімізувати час навчання нейронної мережі без погіршення достовірності автоматизованої класифікації дефектів та точності дефектометрії.

Практична цінність одержаних результатів.

Практичне значення одержаних в дисертаційній роботі результатів полягає в тому, що було розроблено алгоритмічне і програмне забезпечення реалізації підсистеми визначення характеристик дефектів за результатами активного ТНК із використанням вдосконаленого методу на базі нейромережевих технологій, що дозволило автоматизувати класифікацію дефектів і побудову теплових томограм, підвищити точність теплової дефектометрії і достовірність контролю у порівнянні з існуючими методами. Розроблено віртуальний інтерфейс користувача, який містить інструменти для проведення дефектометрії та аналізу теплових томограм, що дало змогу покращити ефективність аналізу результатів контролю. Для розробленої системи експериментально визначено архітектуру та параметри навчання нейромереж, за яких досягається найвища достовірність класифікації дефектів та точність вимірювання їх характеристик. Розроблено та виготовлено

експериментальний стенд та дослідні зразки для проведення активного теплового контролю і аналізу результатів із використанням удосконаленого методу на основі нейромережових технологій, що дозволило відпрацювати програмні алгоритми та підтвердити ефективність даного удосконаленого методу визначення характеристик дефектів.

Впровадження результатів.

Удосконалений метод визначення характеристик дефектів може бути використаний під час проектування підсистем аналізу даних автоматизованих систем теплової дефектоскопії і дефектометрії композиційних матеріалів чи інших об'єктів контролю в різноманітних галузях промисловості, або застосовуватися в якості стенду для дослідження існуючих та розробки нових методик активного теплового неруйнівного контролю.

Результати дисертаційної роботи, зокрема, методичне забезпечення щодо проектування та програмної реалізації нейромережових модулів класифікації та вимірювання параметрів дефектів, рекомендації щодо методики активного теплового неруйнівного контролю, розроблений експериментальний стенд та виготовлені тестові зразки із багатошарових композиційних матеріалів зі штучними дефектами використовуються в початковому процесі кафедри приладів і систем неруйнівного контролю Національного технічного університету України «Київський політехнічний інститут імені Ігоря Сікорського».

Особистий внесок здобувача.

Автором самостійно отримано основні положення, які винесено на захист дисертації (обґрунтовано використання нейромережових модулів для автоматизації визначення типу, глибини залягання та розкриття дефектів; розроблено алгоритми побудови теплових томограм на базі відповідей нейромережових модулів; обґрунтовано та синтезовано структуру автоматизованої системи аналізу результатів активного теплового контролю із застосуванням удосконаленого методу визначення характеристик дефектів; досліджено архітектури нейронних

мереж для вирішення задач АТНК та визначено вплив параметрів навчання на ефективність роботи нейромережевих модулів; розроблено експериментальний стенд та дослідні зразки для дослідження ефективності роботи удосконаленого методу визначення характеристик дефектів багатошарових матеріалів; розроблено рекомендації щодо проведення контролю виробів із композиційних матеріалів з використанням створеної системи із використання удосконаленого методу визначення характеристик дефектів).

У наукових роботах, опублікованих в співавторстві, здобувачем особисто зроблено наступне: [93] – обґрунтовано можливості застосування нейронних мереж для обробки інформаційних сигналів неруйнівного контролю, реалізовано та досліджено алгоритми нейронної мережі для класифікації технічного стану об'єкту; [51] – розроблено нейромережеву систему класифікації технічного стану композиційних матеріалів, обґрунтовано ефективність застосування нейронних мереж в якості систем підтримки прийняття рішень у неруйнівному контролі; [83] – проаналізовано сучасний стан та тенденції розвитку методів вирішення зворотних задач теплового неруйнівного контролю, обґрунтовано необхідність застосування нейронних мереж в задачах теплової дефектометрії; [108] – обґрунтовано можливість застосування нейронних мереж для побудови теплових томограм, проведено комп'ютерне моделювання процесу теплової дефектометрії із застосуванням нейронних мереж; [17, 22] – проведено кореляційний, регресійний та дисперсійний аналіз взаємозв'язків між інформативними параметрами теплового контролю; [135] – проведено формування навчальних множин вхідних даних з різними характеристиками, навчено моделі нейронних мереж та встановлено вплив розглянутих параметрів на ефективність розробленої системи; [38] – проведено аналітичний огляд існуючих методів цифрової обробки термограм, встановлено переваги використання нейронних мереж перед традиційними методами; [97] – обґрунтовано доцільність використання нейронних мереж зворотного поширення помилки в задачах теплової томографії, проведено комп'ютерне моделювання процесу активного теплового контролю сталеві пластины та побудовано її теплову томограму; [52] – проведено

комп'ютерне моделювання активного теплового контролю сталеві пластини та обґрунтовано можливість підвищення достовірності контролю із застосуванням нейронних мереж; [134] – проведено навчання нейронних мереж класифікації та визначення глибини залягання і розкриття дефектів, встановлено вплив обсягу та якості навчальної вибірки на результати роботи відповідних мереж.

Апробація результатів дисертації.

Основні положення дисертаційної роботи були представлені на наступних конференціях:

- Міжнародні науково-технічні конференції «Приладобудування: стан і перспективи», м. Київ, 2017 – 2019 рр.
- Міжнародна науково-технічна конференція «IEEE First Ukraine Conference on Electrical and Computer Engineering (UKRCON)», м. Київ, 2017 р.;
- Міжнародна науково-технічна конференція «НК в контексті асоційованого членства України в ЄС», м. Люблін, 2018 р.;
- Міжнародна науково-технічна конференція «IEEE First International Conference on System Analysis & Intelligent Computing (SAIC)», м. Київ, 2018 р.;
- Міжнародна науково-технічна конференція «Приборостроение-2018», м. Мінськ, 2018 р.
- Міжнародна науково-технічна конференція «НК в контексті асоційованого членства України в ЄС», м. Київ, 2019 р.;
- 9-а Національна науково-технічна конференція і виставка «Неруйнівний контроль та технічна діагностика – UkrNDT-2019», м. Київ, 2019 р.

Проміжні результати досліджень доповідались та обговорювались на наукових семінарах кафедри приладів і систем неруйнівного контролю КПІ ім. Ігоря Сікорського.

Публікації.

Основний зміст, наукові положення та результати дисертації опубліковано в 14 наукових працях, з них: 4 статей у наукових фахових виданнях України, 1 стаття у виданні іноземної держави, 9 матеріалів тез доповідей на міжнародних та національних науково-технічних конференціях (з яких 2 включені до міжнародних науково-метричних баз).

Структура та обсяг дисертації.

Дисертація містить вступ, чотири розділи, загальні висновки по роботі, список використаних джерел із 138 найменувань, 3 додатки. Дисертаційна робота викладена на 192 сторінках, основний зміст роботи становить 150 сторінок друкованого тексту, в тому числі 60 рисунків і 17 таблиць.

РОЗДІЛ 1

АНАЛІЗ СУЧАСНОГО СТАНУ ТА НАПРЯМІВ РОЗВИТКУ МЕТОДІВ АКТИВНОГО ТЕПЛОВОГО КОНТРОЛЮ ВИРОБІВ ІЗ БАГАТОШАРОВИХ МАТЕРІАЛІВ

1.1. Опис об'єкта та обґрунтування методу контролю

На даний час вироби із багатошарових та композиційних матеріалів набувають все більш широкого розповсюдження. Спостерігається постійне розширення номенклатури виробів із КМ та областей їх застосування. Особливості структури, унікальні властивості та складність неруйнівного контролю таких матеріалів викликають значний науковий інтерес.

КМ – вельми складні об'єкти для контролю, оскільки характеризуються істотною неоднорідністю структури, анізотропією властивостей, великою різноманітністю типів армування (односпрямований, поздовжньо-поперечний, комбінований тощо), специфічними фізичними властивостями: високими електроізоляційними якостями, низькою теплопровідністю, звукоізоляцією, великою різноманітністю фізико-механічних характеристик, малими значеннями густини ($0,03 \dots 2,0 \text{ г / см}^3$). Для композитів у одних і тих же фізичних методах дефектоскопії відношення сигнал/шум менше, ніж для однорідних структур (металів). Тому для одних і тих ж методів НК чутливість і роздільна здатність стосовно композитів нижче, ніж для металів або інших однорідних матеріалів [1].

За визначенням, композиційний матеріал являє собою суцільний неоднорідний матеріал, який містить мінімум два компоненти. Для забезпечення високих механічних властивостей матеріалу в композитах використовуються армуючі елементи. Зв'язок та спільна робота армуючих елементів здійснюється за допомогою матриці. Міцність зв'язку між матрицею та армуючими елементами і співвідношення їх властивостей визначають механічну поведінку КМ. Комплексні властивості матеріалу, його працездатність та ефективність залежать від

коректного підбору початкових компонентів та технології їх поєднання. Метою є збереження початкових характеристик вихідних матеріалів та одночасне забезпечення надійного зв'язку між ними. Поєднання армуючих елементів з матрицею не лише зберігає особливості вихідних матеріалів, але і надає отриманій структурі нові властивості. Наприклад, значно підвищується стійкість матеріалу до тріщин завдяки наявності границь розподілу між матрицею та армуючими елементами. Збільшення статичної міцності в КМ призводить до підвищення в'язкості руйнування, що докорінно відрізняє їх від однорідних металів [2].

В процесі полімеризації композитів, під час їх виготовлення внаслідок внутрішніх напружень, нерівномірного розподілу з'єднуючого матеріалу та інших технологічних факторів можуть виникати розшарування, відшарування окремих шарів, рихлість, тріщини тощо. Також можливі обриви ниток, джгутів арматури та інших елементів (рис. 1.1). Інколи можуть зустрічатись включення сторонніх матеріалів. Основні типи дефектів, причини їх виникнення та вплив на механічні характеристики виробів з КМ докладно викладені в роботах [3] та [4].




Рис. 1.1. Дефекти КМ: а – пори, б – тріщини, в – розшарування, г – хвилястість

На відміну від металів, в процесі експлуатації дефекти КМ можуть стрімко збільшуватися, що призводить до зниження надійності конструкції. Через поверхневу тріщину матриці всередину композиту може проникнути волога та призвести до його розриву і відповідного зниження модуля пружності. Частий дефект у вигляді розшарування призводить до зниження міцності на стиск, обриву волокон, зменшує зусилля на розрив [5].

1.1.1. Актуальність удосконалення методів контролю виробів із композиційних матеріалів

Композиційні матеріали значно перевершують метали та їх сплави за такими основними параметрами, як питома міцність, надійність, жаро- і ерозійна стійкість. Ці переваги призвели до широкого використання КМ в авіації, автомобільній промисловості, будівництві та інших галузях. Найчастіше КМ використовують у складі відповідальних деталей та конструкцій, які перебувають під високим навантаженням та в складних експлуатаційних умовах. Від технічного стану виробів з КМ може залежати не лише працездатність дорогого обладнання, але і людські життя, тому до їх надійності висуваються дуже високі вимоги [6].

На результати контролю КМ впливає велика кількість випадкових факторів, обумовлених змінами властивостей композитів, які виникають внаслідок складності процесів їх виготовлення, великою кількістю типів можливих дефектів, які не піддаються формалізованому опису, недосконалістю методик контролю та дефектоскопічного обладнання тощо. Особливості властивостей і фізичних характеристик КМ ускладнюють використання багатьох існуючих методів НК, що використовують, в основному, детерміновані моделі та відповідні їм методи обробки даних та не забезпечують необхідну завадостійкість, точність вимірювань і достовірність контролю [7].

Система контролю та дефектометрії виробів з КМ повинна розділяти сигнали, приймаючи до уваги велику кількість інформативних параметрів, що характеризують ОК. Визначення параметрів дефектів ускладнюється внутрішньою будовою композитів, що не дозволяє використовувати існуючі моделі для ефективного вирішення обернених задач [8].

Таким чином, існує необхідність у розробці нових методик та систем контролю виробів з КМ. Велика кількість взаємопов'язаних інформативних параметрів, неможливість лінійного розділення класів за діагностичними ознаками, потреба в автоматизації та підвищенні інформативності контролю вимагають застосування новітніх систем обробки інформації, зокрема, на базі НМ.

1.1.2. Огляд методів неруйнівного контролю композиційних матеріалів

За своєю фізичною природою, переважна більшість типів КМ є поганими провідниками або діелектриками, в залежності від виду використаного наповнювача. Майже всі КМ є немагнітними матеріалами, що суттєво обмежує коло методів НК, що можуть бути застосовані для контролю виробів з КМ.

Ультразвукові методи НК знаходять обмежене використання для контролю композитів. Це пов'язане з тим, що високочастотні ультразвукові хвилі зазнають сильного послаблення і розсіювання матрицею, волокнами та іншими включеннями. Внаслідок значного згасання та істотних реверберацій суттєво обмежується діапазон контрольованих товщин КМ [9]. Окрім того, в деяких випадках неможливо застосувати методи, які передбачають змочування поверхні ОК, оскільки певні види КМ мають здатність вбирати вологу.

Для контролю КМ та багатошарових клеєних конструкцій застосовують переважно низькочастотні методи акустичного НК. Найбільш ефективними є методи із застосуванням сухого контакту перетворювача з поверхнею ОК, або безконтактного перетворювача [10]. Дані низькочастотні методи використовуються в основному для контролю КМ на основі органічних, борних, скляних або вуглецевих волокон з метою виявлення областей порушення з'єднань в багатошаровій структурі. Наведені акустичні методи дозволяють виявляти дефекти в зонах порушення клейового з'єднання між неметалевою матрицею та армуючими матеріалами об'єкта.

Низькочастотні акустичні методи мають ряд переваг перед іншими методами НК багатошарових матеріалів. Зокрема, відсутня необхідність змочування конструкцій або занурення їх в рідину, що дозволяє проводити контроль деталей і агрегатів з гігроскопічних матеріалів. Окрім того, дані методи дозволяють проводити контроль об'єктів з нерівною поверхнею та виробів складної геометрії. До недоліків можна віднести складність інтерпретації отриманих даних та автоматичної класифікації дефектів, що потребує пошуку засобів підвищення інформативності та достовірності контролю [11].

Часто для контролю КМ використовується метод вільних коливань, який заснований на аналізі характеристик вільних коливань виробу, що вібрує після удару [12]. Цей метод з відповідним обладнанням широко використовується для визначення розшарувань, повітряних порожнин та непроклеїв. Зони з порушенням зчеплення шарів, що не мають заповненого газом проміжку, низькочастотними акустичними методами не виявляються.

Радіаційний контроль також є одним із найбільш поширених способів діагностики КМ [13]. Висока роздільна здатність та інформативність рентгенографії призвели до широкого розповсюдження даного методу. Особливо ефективні радіаційні методи для виявлення розшарувань, пор, сторонніх включень, неоднорідності структури, пропусків або обривів армуючих елементів. Водночас, рентгенівські методи не дозволяють виявляти дефекти, які орієнтовані перпендикулярно напрямку просвічування.

Комп'ютерна томографія є ефективним засобом отримання зображення внутрішньої структури будь-яких об'єктів. На даний час, роздільна здатність методу сягає декількох мікрометрів. Це дозволяє виявляти окремі вуглецеві волокна та їх обриви в вуглепластиках [14]. Суттєвим обмеженням є вимоги до геометрії та розмірів ОК.

Тепловий контроль є одним із найперспективніших напрямів НК виробів з КМ [15]. Чутливість сучасного тепловізійного обладнання дозволяє зафіксувати навіть незначні зміни в тепловому полі ОК. Це дозволяє фіксувати мінімальні температурні аномалії, які виникають в місцях концентрації енергії під час механічних навантажень. Активний тепловий контроль є безконтактним, відносно простим та безпечним і дозволяє проводити дослідження широкого кола виробів, що робить його одним із найбільш універсальних методів НК. На сьогоднішній день методом ефективно визначаються координати і поперечні розміри дефектів, в той час як для вимірювання інших параметрів необхідно вирішувати обернені задачі нестационарної теплопровідності [16]. Недоліком методу також є високі рівні завад та складність забезпечення рівномірного нагріву ОК. За сукупністю властивостей, тепловий НК є оптимальним методом контролю КМ.

1.1.3. Фізичні принципи активного теплового неруйнівного контролю

Методи ТНК завдяки ряду переваг застосовуються для вирішення широкого спектру задач. Якість отриманих термограм, які відображають розподіл інтенсивності теплового поля об'єкту контролю, залежить від багатьох факторів. Теплові зображення часто містять високі за рівнем шуми та завади, а характер теплових відбитків дефектів не завжди дозволяє зробити однозначні висновки щодо їх розміру, форми, положенню, глибині залягання. У зв'язку з цим, в багатьох випадках неможливо проаналізувати технічний стан ОК, використовуючи лише один інформативний параметр – температуру. Відомо, що гістограми розподілу температур в дефектних та бездефектних областях частково перекривають одна одну, що знижує надійність прийняття рішення [17]. Тому актуальним завданням є пошук додаткових інформативних параметрів, аналіз яких дозволить підвищити достовірність контролю.

Динамічне теплове поле описується функцією $T(x,y,\tau)$. Під час проведення активного теплового неруйнівного контролю розглядається характер зміни миттєвих значень температури в часі в точках поверхні об'єкту контролю. Для отримання даних залежностей, об'єкт контролю протягом певного часу нагрівають джерелом теплового потоку. Процес нагріву та подальшого охолодження ОК реєструється за допомогою тепловізора. Отримана послідовність термограм відображає зміну температурного поля на поверхні ОК в часі [18].

Розглядаючи температурну динаміку в окремих точках термограм (пікселях), що відповідають координатам поверхні ОК, можна побудувати температурний профіль – графік зміни температури в часі для даної ділянки (рис. 1.1). Як правило, в бездефектних областях характер зміни температури є постійним і вважається відомим (крива 1 на рис.1.1). При цьому можна ввести деяке еталонне значення температури $T_{nd}(x_{nd}, y_{nd}, \tau)$, яке приймається за бездефектне. В зоні дефекту регулярний характер теплового поля порушується та виникають локальні перепади температури $T_d(x,y,\tau)$, які призводять до зміни температурного профілю (крива 2 на

рис.1.2). Таким чином, можна обчислити значення різниці температур між дефектними та бездефектними областями:

$$\Delta T(x, y, \tau) = T_d(x, y, \tau) - T_{nd}(x_{nd}, y_{nd}, \tau) \quad (1.1)$$

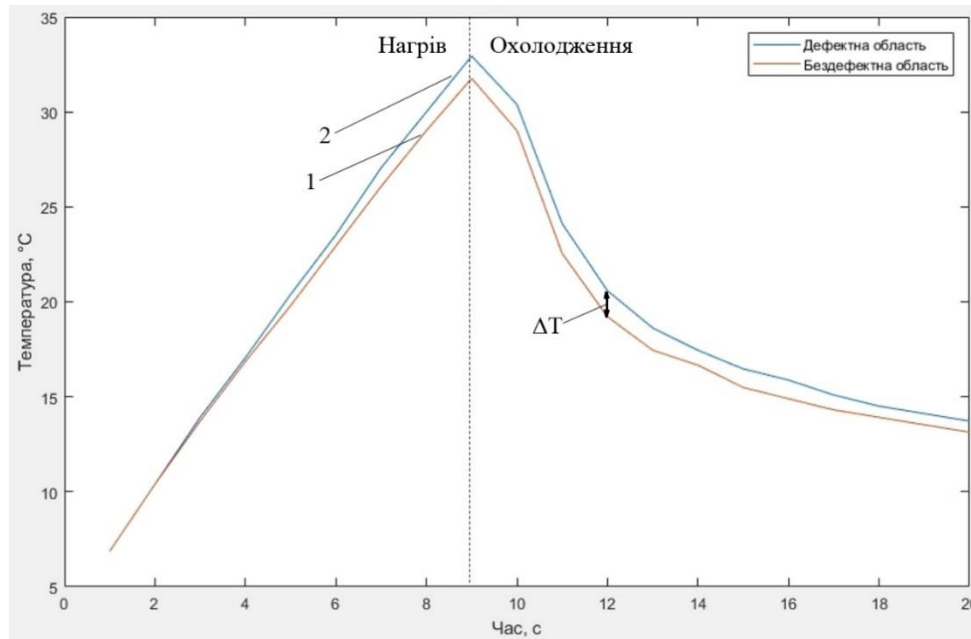


Рис. 1.2. Температурні профілі для дефектної та бездефектної ділянок ОК

Час τ_{opt} , при якому значення $\Delta T(x, y, \tau)$ на даній ділянці ОК стає максимальним, називають оптимальним часом контролю:

$$\Delta T_{max}(x, y, \tau) = \Delta T_{max}(\tau_{opt}) \quad (1.2)$$

Важливим параметром, що впливає на форму температурного профілю, є геометричний розмір дефекту $h(x, y, z)$. Відомо, що за сталої товщини z збільшення поперечних розмірів дефекту x та y призводить до збільшення кількості теплоти, необхідної для його нагріву. Даний процес описується рівнянням теплообміну:

$$-\lambda \frac{\partial T(x, y, z = const)}{\partial z} = Q(\tau) - \alpha [T(x, y, z = const) - T_{amb}], \quad (1.3)$$

де λ — коефіцієнт теплопровідності; T — температура в точці нестационарного теплового поля; $Q(\tau)$ — густина теплового потоку джерела випромінювання; α — коефіцієнт теплообміну; T_{amb} — температура оточуючого середовища.

Зі збільшенням розмірів дефекту швидкість його нагріву зменшується, що призводить до зміни форми температурного профілю. Зокрема, для більш глибоких дефектів зменшується значення ΔT_{max} та збільшується час оптимального спостереження τ_{opt} . Однак, для приповерхневих дефектів дана залежність не спостерігається [19].

В роботі [20] стверджується, що розмір дефектів суттєво впливає на величину сигналу ΔT_{max} , та майже не впливає на значення τ_{opt} . Таким чином, можна побудувати лінійні калібрувальні залежності оптимального часу контролю τ_{opt} від глибини залягання l для дефектів з відомими параметрами. Дані залежності є лінійними функціями, що дозволяє оцінити глибину залягання дефектів за відомим оптимальним часом τ_{opt} .

У найпростішому випадку рішення щодо технічного стану ОК приймають за одним інформативним параметром, наприклад, температурою. За умов наявності високих рівнів завад, складної структури ОК та деяких інших чинників, розподіли значень температур в дефектних та бездефектних областях можуть бути подібними, що знижує вірогідність контролю. За допомогою введення додаткових інформативних параметрів можна підвищити статистичні параметри виявлення дефектів. Це обумовлено тим, що в загальному випадку дефектна та бездефектна області можуть перекриватись по одному параметру, але суттєво відрізнитись за іншим параметром. Наприклад, зі збільшенням глибини залягання зростає оптимальний час спостереження τ_{opt} , що дозволяє відокремити внутрішні дефекти від поверхневих шумів. Ще одним інформативним параметром може бути геометричний розмір h температурної аномалії, що дозволяє розділити сигнали від подряпин та внутрішніх дефектів значної площі. Задачі визначення параметрів дефектів за характером температурного поля (теплова дефектометрія) відносяться до класу обернених задач неруйнівного контролю і потребують спеціальних методів розв'язку [21].

В загальному випадку, будь-яка область на поверхні виробу може характеризуватися N параметрами. Рішення щодо ступеню різниці відповідних статистичних розподілів буде прийматися в багатовимірному просторі ознак.

Важливою умовою для ефективного застосування додаткових інформативних параметрів є слабкий взаємозв'язок цих параметрів. Особливий інтерес являє оцінка зв'язку інформативного параметру з певною характеристикою дефекту, наприклад, розміром або глибиною залягання. Статистичний аналіз таких залежностей проведено в роботі [22]. Отримані авторами результати свідчать про складність однозначної інтерпретації даних теплового контролю, обумовлену значною кількістю взаємопов'язаних параметрів. Характер зв'язків переважно складний та нелінійний, що ускладнює обробку даних традиційними статистичними методами.

Окрім статистичних, в тепловій дефектометрії використовуються і математичні методи. Для визначення параметрів дефектів необхідно мати математичну модель процесу теплопередачі, постановку, метод і алгоритм вирішення відповідної оберненої задачі. Питанням моделювання ТНК вперше були присвячені роботи [23] та [24]. Описані там моделі не задовольняють сучасним вимогам точності і швидкодії. Крім того, в відомих роботах форма дефекту вважається прямокутною (смуга, прямокутник або паралелепіпед), що істотно обмежує діапазон застосування описаних моделей. Існуючі способи моделювання дефектів не враховують їх форму і величину розкриву (товщину), що є значним недоліком. Водночас, для здійснення сучасного активного ТНК необхідно вести контроль в реальному масштабі часу, а не витратити значні ресурси на пост-обробку даних. З іншого боку, методи вирішення обернених задач теплового контролю не мають достатнього математичного обґрунтування. Зокрема, не вирішується питання коректності (однозначності) розв'язку ОЗ.

Для вирішення зазначених завдань необхідно створити ефективні математичні моделі ТНК. Для того, щоб врахувати форму і величину розкриву дефекту в [25] запропоновано моделювати дефект умовами теплового неідеального контакту. Використання умов неідеального контакту для моделювання тонких включень є поширеним в різних розділах механіки деформованого твердого тіла і, зокрема, в задачах теплопровідності і термопружності. Для практичного застосування умов неідеального теплового контакту під час моделювання

теплового контролю необхідно вибрати умови контакту, які дозволяють досить точно описати процес теплопередачі, що не завжди є можливим.

Для визначення наявності дефекту і його параметрів математичними методами необхідно вирішити ОЗ, природна постановка якої є некоректною. Теорія розв'язання некоректних задач пропонує різні методи введення задачі в клас коректності шляхом використання додаткової інформації про розв'язок. В такому випадку питання однозначності ОЗ стає одним основним. Одновимірні ОЗ теплового контролю є окремим випадком задачі ідентифікації довільного багат шарового середовища. У ряді практично важливих випадків для підвищення точності визначення параметрів дефектів необхідно використовувати багатовимірні моделі процесу ТНК.

Авторами монографії [26] систематизовано результати в області розв'язку ОЗ і запропоновано умовно ділити ОЗ на наступні типи:

- 1) Ретроспективні – обчислення температурного поля в попередні моменти часу;
- 2) Граничні – відновлення граничних умов;
- 3) Коефіцієнтні – визначення коефіцієнтів рівнянь;
- 4) Геометричні – знаходження геометричних характеристик областей.

ОЗ ускладнюється, якщо перетин структури теплопроникний. Також задача істотно ускладнюється в разі наявності квазістатичної термопружності. Теорія вирішення відповідних (парних) інтегральних рівнянь розроблена недостатньо повно. Відомі розв'язки лише для кількох окремих випадків [27]. Для деяких більш складних задач можна побудувати асимптотичні розв'язки [28]. У загальному випадку для вирішення задач в умовах квазістатичної термопружності доцільно використовувати методи обчислювальної механіки. В роботі [29] дана варіаційна постановка задачі квазістатичної термопружності в прямокутній області з теплопроникним перетином, дискретизація задачі проводиться варіаційно-різницевою методом. Для знаходження розв'язку використовується ітераційний процес. Детальніший розгляд конкретних математичних методів вирішення ОЗ виходить за межі даної дисертаційної роботи.

Отже, аналізуючи форму, амплітудні і часові характеристики температурного профілю, а також частотні, фазові та характеристики потужності температурного сигналу, роблять висновки про розміри, положення, глибину залягання дефектів. Величину розкриття дефектів складно однозначно пов'язати з будь-якою характеристикою сигналу. Для вирішення ОЗ застосовують складні математичні методи, ефективність яких доведена лише для значно спрощених задач. Водночас, результати суттєво залежать від якості записаних термограм, їх кількості, наявності шумів, параметрів нагріву ОК, параметрів використаних під час розрахунків математичних моделей, досвіду оператора тощо. У зв'язку з цим, для покращення достовірності контролю застосовуються спеціальні методи цифрової обробки послідовностей термографічних зображень [30].

1.1.4. Особливості теплового контролю багат шарових матеріалів

Одними з найскладніших об'єктів в області вирішення задач теплового контролю є багат шарові та композиційні матеріали. На даному етапі розвитку ТНК побудовані математичні моделі та отримані аналітичні розв'язки обернених задач переважно для однорідних матеріалів. Теплова дефектометрія КМ вимагає ускладнення існуючих моделей додатковими початковими умовами, умовами на границях середовищ та іншими параметрами. Відомі підходи допускають значних спрощень щодо структури ОК та форми внутрішніх дефектів [31].

Неруйнівний контроль композиційних і багат шарових матеріалів в першу чергу ускладнюється неоднорідністю їх внутрішньої структури. Проблеми ТНК композитів також обумовлені фізичною природою поширення в них теплового фронту. Наявність границь поділу середовищ впливає на складність математичних моделей, які необхідні для вирішення обернених задач традиційними методами. Багат шарова структура призводить до неоднорідності теплопередачі. Водночас, КМ характеризуються наявністю значної анізотропії властивостей [32].

Якість отриманих термограм суттєво залежить від характеристик джерела нагріву та засобу реєстрації теплового поля. Забезпечення рівномірного нагріву на практиці є складним завданням, оскільки на характер нагріву впливають

недосконалості джерела теплового потоку та численні зовнішні фактори, такі як вплив сторонніх випромінювачів, рух повітря тощо. Внаслідок анізотропії характеристик, КМ мають різні значення теплопровідності вздовж координатних осей, що призводить до викривлення форми теплових відбитків дефектів [33].

Вирішення тривимірних обернених задач теплопровідності у випадку дефектометрії КМ вимагає значних обчислювальних витрат. Для отримання відповіді лише для однієї точки необхідно близько 60 с часу навіть із використанням сучасних ПК [34]. Існуючі методи теплової дефектометрії вимагають побудови та розрахунку великої кількості детермінованих математичних моделей ОК для кожного конкретного випадку, що значно знижує продуктивність застосування даних методів.

Особливості будови композитів, їх різноманіття та широка номенклатура, значний розкид теплофізичних характеристик і складність контролю вимагають постійного удосконалення методів виявлення і визначення характеристик дефектів. Актуальним є завдання автоматизації процесу контролю та пошук нових або удосконалення існуючих методів контролю, що забезпечуватимуть високу інформативність, достовірність і точність [35].

1.2. Аналіз традиційних методів обробки термограм

Розподіл температур (теплове поле) об'єкта контролю візуалізується за допомогою тепловізора у вигляді теплових зображень – термограм. Кожна термограма є зображенням, яке складається з пікселів, які забарвлюються певним кольором (що залежить від обраної кольорової палітри та діапазону вимірювання і візуалізації тепловізора). Для задач теплової дефектометрії використовуються вимірювальні тепловізори, піксельні температури яких відповідають радіаційним температурам об'єкта [36]. Таким чином, кожна термограма являє собою матрицю піксельних температур. Амплітудне значення, яке відповідає різним кольорам, кодується числами в форматі RGB. Тоді як чисельні значення температури записуються у форматі чисел з плаваючою точкою.

Оскільки термограми являють собою зображення, для їх обробки застосовуються всі традиційні методи обробки звичайних зображень, такі як фільтрація, вирівнювання гістограми, контрастування і керування яскравістю тощо. Однак, одинична термограма дає змогу оцінити лише наявність дефекту та його поперечні геометричні розміри, в той час як для визначення глибини залягання дефекту або його розкриття необхідно аналізувати характер динамічного теплового поля. Тому під час активного теплового контролю записується послідовність термограм. Розвиток температурних значень кожного пікселю термограми в часі являє собою температурний профіль в даній точці. Для аналізу температурних профілів застосовуються методи цифрової обробки сигналів, наприклад, перетворення Фур'є або вейвлет-аналіз. За допомогою даних методів реалізується, зокрема, алгоритм динамічної теплової томографії. Інший підхід ґрунтується на комплексному статистичному аналізі всієї послідовності термограм, для чого використовується метод аналізу головних компонент. Кожен із даних методів має свої переваги та недоліки, але всі вони використовуються для вирішення окремого вузького кола задач і не є універсальними та адаптивними [37].

В роботі [38] авторами проведено комп'ютерне моделювання процесу активного теплового контролю та обробка його результатів із використанням різних методів аналізу даних. Такими даними виступають послідовності термограм, записані під час активного ТНК спеціальних зразків з відомими параметрами, що містять штучні дефекти відомої конфігурації. Для отримання даних застосовувалися комп'ютерні моделі, що є популярним підходом в задачах порівняння ефективності різних методів визначення характеристик дефектів [39]. Результати проведених досліджень є частиною даної дисертаційної роботи та у стислому вигляді наводяться далі.

1.2.1. Фур'є-аналіз

Одним із методів обробки послідовностей термограм є застосування одновимірного перетворення Фур'є до функції зміни температури у часі $T_{i,j}(\tau)$, яка відображає температурний профіль в точці ОК. Тобто функція зміни піксельного

значення температури на всьому діапазоні вимірювання переводиться у частотну область. В результаті отримують зображення модулю (амплітуди) та фази в Фур'є-просторі – модулограми та фазограми. Кількість модулограм та фазограм дорівнює кількості термограм у послідовності, втім через ефект алайзингу інформативними є лише перша половина з них. Використання перетворення Фур'є дозволяє виявити слабкі закономірності зміни піксельних температур в дефектній та бездефектній областях. Метод отримав назву «імпульсна фазова термографія» [40].

В методі застосовується одновимірне дискретне перетворення Фур'є:

$$F_T = \frac{1}{\sqrt{N}} \sum_{n=1}^N T_n e^{2\pi j(n-1)(f-1)/N}, \quad (1.4)$$

де N – кількість відліків (кількість термограм), T_n – дискретна функція (температурний профіль в точці), j – уявна одиниця, f – частота, n – номер відліку.

Далі знаходять модуль і фазу:

$$\begin{aligned} \text{Magnitude} &= \sqrt{[\text{Re}(T)]^2 + [\text{Im}(T)]^2}; \\ \text{Phase} &= \arctan \left[\frac{\text{Im}(T)}{\text{Re}(T)} \right], \end{aligned} \quad (1.5)$$

де $\text{Re}(T)$ та $\text{Im}(T)$ являють собою реальну та уявну частину перетворення Фур'є, застосованого до функції $T_{i,j}(\tau)$.

Фур'є аналіз традиційно вважається одним із найкращих методів для обробки термограм завдяки високій чутливості, що в більшості випадків дозволяє отримувати високі значення співвідношення сигнал/шум. В роботі [41] показано, що найкращим чином виявляються підповерхневі дефекти. Проте, зазначається, що результат перетворення Фур'є суттєво залежить від кількості термограм у послідовності, а також від інтервалів між ними. Дефекти, що лежать на великій глибині, краще виявляються низькочастотними хвилями, оскільки збільшення частоти призводить до збільшення теплової дифузії. Підповерхневі дефекти оптимальніше досліджувати за допомогою високочастотних хвиль. Тому імпульсна фазова термографія потребує накопичення інформації протягом довгого часу з малим інтервалом між термограмами. Для отримання більш високої

інформативності Фур'є-аналізу зазвичай записується сотні термограм. У випадку, коли кількість термограм у послідовності мала, а інтервал між ними порівняно великий, аналіз отриманих зображень ускладнюється, з'являються артефакти.

Авторами роботи [42] розглянуто особливості застосування імпульсної фазової термографії. Основним недоліком у дослідженнях даного методу є неоднозначність результатів перетворення Фур'є, оскільки від дефектів на різних глибинах залягання можуть виникати різні за знаком значення зсувів фаз, що ускладнює побудову калібрувальних залежностей для дефектометрії. Окрім того, існує певна складність інтерпретації отриманих даних, так як однорідні у фізичному сенсі дефекти можуть давати різні значення зміни фази. Метод забезпечує високу чутливість до структурних дефектів, що у випадку наявності шумів або нерівномірності нагріву може призвести до появи на зображенні сторонніх елементів та хибних дефектів. Враховуючи високі вимоги до тепловізійного обладнання, що необхідні для забезпечення належної ефективності імпульсної фазової термографії, практична реалізація даного методу ускладнена.

1.2.2. Вейвлет-аналіз

Використання вейвлетів є новим способом обробки сигналів, що застосовується для уникнення обмежень, які має перетворення Фур'є. Основною відмінністю перетворення вейвлет від перетворення Фур'є у фізичному сенсі є вид базисної функції. В разі використання перетворення Фур'є сигнал розкладається в ряд за гармонійними функціями. Вейвлет перетворення передбачає використання великого набору інших базисних функцій. Форма вейвлету має бути максимально подібною до форми вхідного сигналу. Тому в ТНК найбільш оптимальним вважається використання вейвлетів Морле, або так званого «мексиканського капелюха», адже їх форма подібна до температурного профілю [43].

Перетворення вейвлет за змістом є кросс-кореляцією вхідного сигналу з деяким набором хвильових функцій різної тривалості (ширини), що і називаються вейвлетами. Вейвлет-перетворення часової послідовності $T(i)$ у дискретній формі має вигляд:

$$C(a,b) = \frac{1}{w(a)} \sum_{i=1}^N g\left(\frac{i-b}{a}\right) T(i), \quad (1.6)$$

де a – параметр масштабу, b – параметр зсуву, $w(a)$ – деяка вагова функція, необхідна для візуалізації перетворення, g – дійсна вейвлет-функція.

Як правило, $w(a) = \sqrt{a}$. Якщо в формулу (1.7) підставити вираз для функції Морле, яка найчастіше застосовується для обробки температурних профілів, отримаємо наступний вигляд дискретного перетворення:

$$C(a,b) = \frac{1}{w(a)} \sum_{i=1}^N T(i) \left[1 - \left(\frac{i-b}{a}\right)^2 \right] \exp \left[-\frac{1}{2} \left(\frac{i-b}{a}\right)^2 \right] \quad (1.7)$$

Вейвлет-перетворення має такі ж особливості, як і перетворення Фур'є. Використовуючи формули (1.6), отримують значення модулів і фаз результатів вейвлет-перетворення. Для виявлення координат дефектів рекомендовано використовувати фазу вейвлет-перетворення. Зміна фактору масштабу a дозволяє оцінити глибину залягання дефектів [44].

В теорії сигналів масштаб a вейвлет-перетворення пов'язують з частотою вхідного сигналу. В разі застосування в ТНК, параметр масштабу можна пов'язати з тривалістю температурного сигналу, тоді як фактор зсуву b обирається на базі оцінки оптимального часу контролю. На практиці часто доводиться обирати значення параметрів a і b емпірично або використовуючи математичні моделі і розрахунки оптимального часу контролю та часу теплової дифузії. Цей факт ускладнює обробку даних та загалом негативно впливає на ефективність контролю, збільшуючи часові та обчислювальні витрати.

Авторами роботи [45] досліджується використання вейвлет-аналізу для обробки результатів теплового контролю композиційних матеріалів. Характерна особливість такого підходу полягає в тому, що вейвлет-перетворення декорелює одновимірну функцію часу в двовимірну функцію зсуву і масштабу. Це призводить до значного збільшення обсягу необхідних розрахунків. Іншим дискусійним питанням є доцільність самого застосування вейвлетів, які показують найбільшу ефективність для виявлення короткотривалих імпульсних сигналів на фоні завад.

Процес зміни температури в часі є порівняно тривалим через характерні особливості теплової дифузії, а сама функція температурного сигналу носить згладжений характер. На даний час не доведена можливість застосування вейвлет-перетворення для оцінки глибини дефектів, відсутні приклади побудови теплових томограм в результаті обробки термограм даним методом. Наразі можливість теплової дефектометрії методом вейвлет-аналізу є погано вивченою [46].

1.2.3. Метод аналізу головних компонент

Статистичний метод аналізу головних компонент (англ. *principal component analysis*) базується на перетворенні Карунена-Лоєва та є одним із найбільш ефективних методів для обробки багатовимірних даних. Головною перевагою методу є зниження розмірності простору ознак без значної втрати інформації. В загальному випадку, за допомогою даного методу можна зменшити розмірність даних D та кількість вимірювань N , які представлені матрицею вхідних даних X розмірністю $D \times M$. Як правило, багато змінних у матриці даних так чи інакше пов'язані між собою та не є незалежними. Метод передбачує введення K нових ортогональних осей та проектування на них початкових даних. Це дозволяє зменшити розмірність матриці X до $M \times K$ [47].

В разі застосування методу аналізу головних компонент для обробки даних активного ТНК використовується наступний алгоритм. Нехай існує набір початкових даних, що складається з $n=20$ термограм. Кожна термограма складається з $m=240$ рядків пікселів та $k=320$ стовпчиків пікселів. Необхідно представити вхідний набір даних у вигляді однієї матриці X розмірністю $n \times d$, $d=m \cdot k$, в даному випадку 20×76800 . Для цього піксельні значення кожної термограми записуються у вигляді вектора-рядка довжиною $m \cdot k$. Таким чином, кожна термограма послідовності з двовимірної матриці піксельних значень трансформується в одновимірний вектор. Число таких векторів буде дорівнювати числу термограм у послідовності n . В результаті послідовного запису всіх векторів в одну спільну матрицю отримується бажаний формат вхідних даних $X(d \times n)$. Далі виконуються наступні операції:

- 1) Значення векторів-рядків нормуються та приводяться до нульового середнього:

$$\mu_i = \frac{1}{n} \sum_{j=1}^n x_{ij}, \quad (1.8)$$

$$x_{ij} = x_{ij} - \mu_i \quad (1.9)$$

- 2) Значення рядків приводяться до 1-ї дисперсії:

$$\sigma_i = \sqrt{\frac{1}{n-1} \sum_{j=1}^n (x_{ij} - \mu_i)^2}, \quad (1.10)$$

$$x_{ij} = \frac{x_{ij}}{\sigma_i} \quad (1.11)$$

- 3) Обчислюється коваріаційна матриця: $Cv = XX^T$.
- 4) Обчислюються власні вектори W^T коваріаційної матриці Cv .
- 5) Кожний рядок отриманої коваріаційної матриці називається головною компонентою. Як правило, корисну інформацію містять лише декілька p перших головних компонент, інші відкидаються. Часто користуються правилом Парето, залишаючи перші 20% головних компонент.
- 6) Початкову матрицю X проєктують на матрицю власних векторів $W^T \times X$ для отримання зображення.

В результаті процедури отримується нова матриця Y розмірністю $p \times d$.

Використання МАГК в тепловому контролі досліджувалося авторами роботи [48]. В статті обґрунтовано покращення виявлення відкритих тріщин на якісному рівні та підвищення співвідношення сигнал/шум в разі застосування методу для обробки послідовності термограм. Проте нерівномірність нагріву та інші фактори призвели до неможливості коректного відокремлення інформації про дефекти та завади. На даний час не існує універсальних алгоритмів максимізації співвідношення сигнал/шум методом аналізу головних компонент, що вимагає додаткових досліджень для кожної конкретної задачі контролю.

Дослідження можливостей застосування МАГК в задачах класифікації дефектів або теплової дефектометрії на даний час не проводились. Існує теоретична можливість формування бази даних власних векторів та відповідних ним типів дефектів. В той же час, в задачах класифікації МАГК розділяє простір ознак не з метою отримання оптимальної границі класів, а для якомога кращої апроксимації вхідного набору даних. Цей факт призводить до зменшення ефективності методу в разі наявності нерівномірності нагріву або інших випадкових завад, а також зміни параметрів і умов проведення контролю.

1.2.4. Динамічна тепла томографія

Температурний сигнал $\Delta T(i, j, \tau)$, тобто різниця температур дефектної і бездефектної ділянки ОК в кожен момент часу вимірювання є основним інформативним параметром теплового неруйнівного контролю. Максимальне значення даного диференціального сигналу ΔT_{max} виникає в момент оптимального часу спостереження дефекту τ_{opt} . Час появи максимального температурного контрасту τ_{opt} зростає зі збільшенням глибини залягання дефектів l . Важливою особливістю є слабкий вплив геометричного розміру дефектів на значення τ_{opt} . Водночас, розміри дефектів мають значний вплив на величину температурного сигналу ΔT_{max} . Відповідно, для дефектів конкретних розмірів існує можливість побудови лінійних калібрувальних залежностей оптимального часу контролю τ_{opt} від глибини залягання l . Оскільки подібні функціональні залежності носять лінійний характер, їх використання дозволяє досить просто оцінити глибину залягання дефектів, якщо відомий час оптимального спостереження τ_{opt} . На даних принципах базується метод динамічної теплової томографії, алгоритм якого детально розглянутий в роботі [49].

Під час застосування методу ДТТ на основі записаної послідовності термограм отримують два зображення. Перше з них називають максіграмою. Кожен піксель максіграми відображає максимальне значення температурного сигналу ΔT_{max} в даній точці термограми на всьому інтервалі вимірювання. Таким чином, на максіграмі відображено відбитки дефектів в момент їх оптимального

виявлення, незалежно від моменту спостереження. Друге зображення отримують в результаті фіксації часу появи ΔT_{max} в даній точці (на практиці використовують не час, а номер відповідної термограми) та називають таймограмою. Іншими словами, на таймограма є масивом піксельних значень, що відповідають оптимальним часам спостереження τ_{opt} на всьому інтервалі вимірювання. Відповідно, в максіграмі та таймограмі міститься інформація про властивості всією початкової послідовності термограм. Зведення цілого набору початкових даних лише до двох зображень є однією з головних переваг методу ДДТ.

Дані максіграм та таймограм в комбінації з лінійними калібрувальними залежностями часу оптимального спостереження від глибини залягання дефектів дозволяють отримати теплову томограму – зображення внутрішньої структури об'єкта контролю. Для цього ОК умовно поділяють за товщиною на певну кількість прошарків. Дискретність оптимального часу контролю τ_{opt} відповідає часовому інтервалу між сусідніми термограмами послідовності та визначає мінімальну товщину прошарку. Використавши відому калібрувальні залежності, можна визначити повздовжню роздільну здатність методу. Цей параметр сильно залежить від характеристик тепловізійної апаратури, оскільки фактично визначається кадровою частотою запису термограм.

На сьогоднішній день існують модифікації методу ДДТ, завдяки яким покращується ефективність методу в задачах дефектометрії [50]. Наявні дослідження присвячені застосуванню методу для обробки якісних послідовностей термограм, що не містять високих рівнів завад у вигляді шумів, нерівномірності нагріву чи недосконалості апаратури. Штучні дефекти у досліджених зразках розташовані на великій відстані один від одного, що виключає можливість взаємовпливу теплових полів температурних аномалій. Такий підхід не доводить результативність методу в реальних умовах. Окрім того, алгоритми ДДТ ґрунтуються на апіорній інформації про параметри контролю та теплофізичні характеристики ОК для побудови лінійних калібрувальних залежностей. В ряді випадків отримання такого роду інформації є ускладненим.

1.3. Застосування нейронних мереж в тепловій дефектометрії

1.3.1. Обґрунтування можливості застосування нейронних мереж для обробки послідовностей термограм

Характер температурного сигналу $\Delta T(i,j,\tau)$, отриманого за результатами активного теплового контролю, залежить від багатьох факторів, серед яких: час вимірювання, параметри нагріву, інтенсивність теплообміну ОК з навколишнім середовищем, товщина ОК, теплофізичні властивості ОК, геометричні розміри дефекта та глибина його залягання, теплофізичні характеристики дефекту тощо. Всі ці фактори пов'язані між собою складним чином, що значно ускладнює побудову математичних моделей для розв'язання задач дефектометрії. Також на практиці традиційними методами фактично неможливо встановити чіткі границі класів для ефективної класифікації дефектів [38].

Вагомою тенденцією в розвитку сучасних систем обробки даних є застосування штучного інтелекту, зокрема, нейронних мереж. Завдяки спеціальним алгоритмам навчання нейронні мережі набувають здатності автоматично виявляти складні приховані закономірності у взаємозв'язках між вхідними даними. Традиційні математичні методи не дозволяють лінійно розділити простір діагностичних ознак в тепловому контролі. НМ здатні вирішувати багатопараметрові задачі та ефективно працювати зі складними нелінійними залежностями, тому можуть бути застосовані в якості класифікаторів образів та засобів побудови регресійних моделей [51].

Нейромережеві системи можуть застосовуватися в ТНК для розв'язання широкого кола задач. Наприклад, у випадку навчання НМ для обробки послідовностей термограм на її вхід подаються теплові профілі в пікселях термограм. Зразкам дефектних і бездефектних профілів ставлять у відповідність номер класу (наприклад, 0 – бездефектний, 1 – дефектний). В результаті навчання НМ виявляє приховані залежності у температурних профілях, які притаманні певному класу дефектів або бездефектним ділянкам. НМ використовуються для класифікації дефектів, визначення їх параметрів, побудови теплових томограм [52].

1.3.2. Опис основних принципів роботи нейромережових систем

Штучні нейронні мережі є математичними моделями біологічної структури мозку та його функцій сприйняття, обробки, зберігання та продукування інформації. Головною особливістю біологічних НМ є здатність до навчання та самоорганізації на основі набутого досвіду. Нейронні мережі мозку побудовані з великої кількості з'єднаних між собою клітин – нейронів. Моделі нейромереж організовані за схожим принципом, але мають ряд обмежень. Штучні нейронні мережі є груповим об'єднанням штучних нейронів. Дані об'єднання утворюють прошарки, які також з'єднуються між собою [53].

Структура типової штучної нейронної мережі показана на рис. 1.3. Як правило, кожна нейронна мережа складається мінімум з трьох базових прошарків: вхідного, прихованого та вихідного. Відомі також архітектури, що містять меншу кількість прошарків, або лише один обчислювальний елемент. В деяких джерелах вхідний та вихідний прошарки мережі не враховуються, тому зазначається, що мережа містить один прошарок. На даний час порядок нумерації не регламентований. Вхідний прошарок мережі призначений для отримання даних з датчиків або зовнішніх файлів. Вихідний прошарок передає відповідь мережі до інших блоків системи або програми. Всі основні обчислення відбуваються у прихованих прошарках, які містять набори з певної кількості нейронів. Входи прихованих нейронів приймають дані з попереднього прошарку, виходи – передають обчислене значення нейрона на наступний прошарок [54].




Рис. 1.3. Схема типової нейронної мережі

Фундаментальною особливістю біологічного мозку є здатність навчатись. У випадку штучних НМ навчання розглядається як процес визначення синаптичних ваг, що пов'язують нейрони між собою. Спосіб навчання залежить від конкретної задачі. НМ навчається за допомогою спеціальної множини навчальних даних. Ця особливість робить НМ більш гнучкими та привабливими, ніж використання традиційних програмних алгоритмів [55].

Конкретні особливості перетворень у НМ визначаються параметрами нейронів, архітектурою та структурою мережі, способами синхронізації та управління інформативними даними. Вибір оптимальної кількості прихованих прошарків, кількості нейронів та видів зв'язків між ними значно впливає на ефективність мережі. Для опису НМ часто застосовуються терміни, які можуть мати різне значення в різних джерелах. Такими поняттями можуть бути:

- *структура нейромережі* - спосіб зв'язків нейронів у нейромережі;
- *архітектура нейромережі* - структура нейромережі та типи нейронів;
- *парадигма нейромережі* - спосіб навчання та використання; іноді вміщує і поняття архітектури.

На основі однієї архітектури можуть бути реалізовані різні парадигми нейромережі і навпаки [56]. Такий розподіл є відносно теоретичним. Провівши аналіз існуючих на даний час нейронних мереж, можна зробити висновок, що найбільш поширеною архітектурою є багатошарові мережі. У такому випадку нейрони об'єднуються в прошарки з одним спільним вектором вхідних сигналів. Цей вхідний вектор подається з зовнішнього джерела на вхідний прошарок мережі, нейрони в якому інколи називають рецепторами. Сигналом на виході є значення нейронів останнього прошарку (ефектори). Між вхідним та вихідним прошарками така мережа містить один або декілька прихованих прошарків, які не мають зв'язків з зовнішніми структурами та є закритою внутрішньою системою. Від числа прихованих прошарків та кількості нейронів в них залежать обчислювальні можливості мережі та ефективність її роботи [57].

За фактом, переважну більшість відомих нейронних мереж, що застосовуються на практиці, можна віднести до двох загальних класів за архітектурою:

1. З послідовними односкерованими зв'язками (НМ прямого поширення).
2. З рекурентними зв'язками (НМ зворотного поширення).

Мережі прямого поширення, в свою чергу, відносять до статичних, оскільки на вхід мережі подається незалежний від попереднього стану мережі вхідний вектор. Мережі зворотного поширення є динамічними, так як входи нейронів змінюються завдяки наявності зворотних зв'язків, що впливає на стан мережі. В залежності від типу, змінюється сфера застосування даної НМ. Вибір типу мережі є одним з основних завдань під час проектування інтелектуальних систем. В таблиці 1.1 наведені найбільш типові архітектури нейромереж, кожна з яких може мати додаткові модифікації або застосовуватись в складі інших мереж. Даний перелік не є вичерпним, оскільки завдяки бурхливому розвитку області постійно з'являються нові типи нейронних мереж [58].

1.3.3. Модель штучного нейрона

Біологічний нейрон складається з тіла (соми) та гілкоподібних розгалужень – дендритів і аксонів. Базовим елементом тіла клітини є ядро, яке забезпечує функціонування нейрона. Дендрити працюють в якості приймачів імпульсів нервових сигналів, а аксони призначені для передачі сигналу тіла клітини до наступних нейронів. Аксон розгалужується на волокна, на закінченнях яких знаходяться синапси. Таким чином, аксони нейрона зв'язують його с дендритами інших нейронів через синаптичні зв'язки [59].

Розглянута будова нейрона є значно спрощеною. Існуюча модель штучного нейрона включає лише базові чотири функції біологічного нейрона (рис. 1.4). На вході штучний нейрон приймає вектор вхідних сигналів $[x_0 \dots x_n]$, зважує його елементи значеннями синаптичних ваг $[w_0 \dots w_n]$ та обчислює зважену суму. Отримане значення проходить через функцію активації нейрона, що по суті є передатною функцією. Обчислений результат є вихідним значенням нейрона [60].

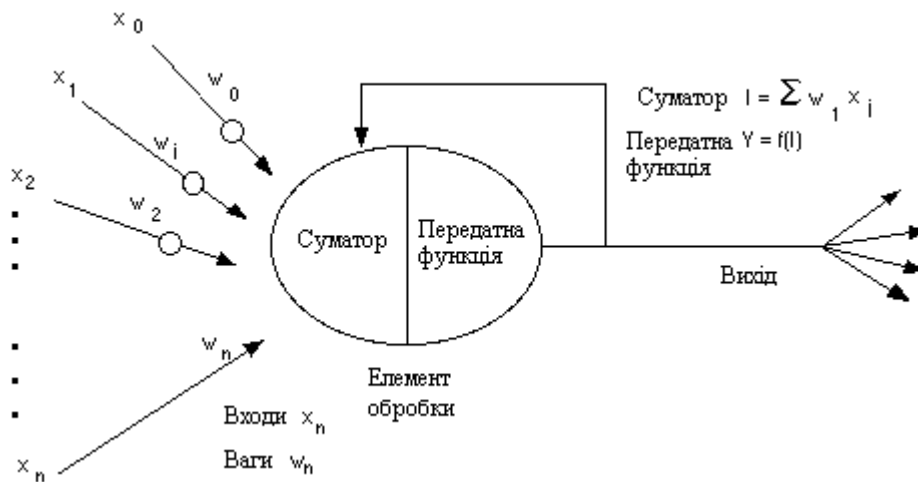


Рис. 1.4. Базовий штучний нейрон

Вибір активаційної функції значно впливає на результат роботи нейрона. На сьогоднішній день найбільш часто застосовуються логістичні функції, але в залежності від задач можуть бути використані функції гіперболічного тангенса, гармонічні чи порогові функції [61]. Результат застосування активаційної функції до зваженої суми входів нейрона є його фінальною відповіддю, яка передається далі на вхід інших нейронів мережі або надходить до зовнішньої структури. Результатом роботи мережі є значення нейронів її вихідного прошарку.

1.3.4. Багатошарова нейронна мережа

Найбільший розвиток на сьогоднішній день отримали багатошарові нейронні мережі (рис. 1.5). Така мережа побудована з кількох прошарків нейронів. Окремий нейрон прошарку зв'язаний синаптичними вагами $w_{i,j}$ з усіма нейронами наступного прошарку. У вхідному прошарку містяться нейрони, які не виконують жодних обчислень та призначені для прийому і передачі до мережі вхідного вектора $[i_1, i_2, \dots, i_n]$, який складається з n елементів (відліків сигналу). В нейронах прихованих прошарків відбувається перетворення отриманих вхідних даних:

$$A = \sum X(j) * W(i, j) + b(i), \quad (1.12)$$

Обчислене значення нейрона A пропускається через активаційну функцію. В результаті, можна записати в загальному вигляді рівняння нейрона зі зміщенням:

$$y = f(wx + b), \quad (1.13)$$

де $X(j)=[x_1, x_2, \dots, x_j]$ – вектор даних з виходу нейронів попереднього прошарку, j – кількість нейронів у попередньому прошарку, i – індекс поточного нейрона, $b(i)$ – зміщення поточного нейрона.




Рис. 1.5. Схема класичної багатошарової нейромережі

Значення виходів нейронів прошарку передається нейронам наступного прошарку. Останній прошарок багатошарової мережі називається вихідним, значення його нейронів $[o_1, o_2, \dots, o_n]$ передаються до наступних функціональних блоків нейромережевої системи.

Наразі не існує чітких правил підбору числа прихованих прошарків та кількості нейронів в них. Вибір параметрів мережі відбувається у відповідності до загальних рекомендацій або емпірично [62]. Після визначення архітектури та вибору активаційних функцій відбувається процес навчання нейронної мережі.

1.3.5. Принципи навчання нейронних мереж

Здатність до навчання за зразками, які формують навальну множину, є головною особливістю нейронних мереж. Процедуру навчання НМ можна

розглядати як ітеративний процес корекції значень синаптичних ваг таким чином, щоб мережа виконувала необхідну задачу найбільш оптимально. Іноді до поняття навчання відносять і процес визначення архітектури мережі [63].

Загальний принцип навчання можна описати як послідовну подачу на вхід мережі векторів навчальних даних $X(i)$ з відомими правильними відповідями $Y(i)$, які називають цілями. Далі виконується оцінка різниці наявної відповіді мережі та необхідного результату. Найчастіше для цього розраховується середньоквадратична похибка та визначається середньоквадратичне відхилення. Основною метою навчання з математичної точки зору є мінімізація функції похибки за допомогою зміни значень синаптичних ваг. В результаті коректного навчання мережа отримує здатність працювати зі зразками, які не були їй представлені протягом навчання. Існує дві основних парадигми навчання: контрольоване та неконтрольоване [64].

Контрольоване навчання. Переважна більшість практичних застосувань нейронних мереж побудована на використанні алгоритмів контрольованого навчання, або навчання «з вчителем». Такий алгоритм передбачає порівняння поточних значень на виході мережі з бажаними. На початку навчання синаптичні ваги ініціалізуються випадковими значеннями, а далі коригуються з метою досягнення найкращої відповідності між поточним та бажаним результатом на виході. Задовільна точність мережі досягається шляхом мінімізації похибок, які в наслідок проходження через мережу всіх навчальних зразків утворюють функцію помилки. Саме ця помилка розглядається як помилка мережі. В якості функції помилки може виступати СКВ, але найчастіше на практиці використовується сума квадратів похибок [65].

Кожна ітерація навчання включає проходження через мережу всієї множини навчальних зразків. Одна така ітерація називається епохою. Для налаштування значень синаптичних ваг може використовуватись як функція помилки, так і градієнт поверхні станів. В останньому випадку для мінімізації найчастіше користуються методом найшвидшого спуску. Критеріїв зупинки навчання може бути декілька, але навчання зупиняється у випадку досягнення одного із них. В

якості таких критеріїв можуть використовуватись кількість виконаних епох, досягнення бажаного значення помилки або припинення її зменшення. Зростання помилки на тестовій множині може свідчити про перенавчання [66].

Множини навчальних векторів мають бути достатньо об'ємними для кращого представлення інформації, яка містить приховані зв'язки та особливості між даними. Водночас, навчальні зразки мають бути різноманітними та найбільш повно описувати всю множину даних.

Неконтрольоване навчання. Навчання «без вчителя» вважається одним із найбільш перспективних напрямів розвитку нейромережових технологій. На сьогоднішній день самонавчання використовується здебільшого у вузькому колі задач. Зокрема, на даному принципі побудовані самоорганізовані карти Кохонена або мережі адаптивної резонансної теорії. Неконтрольоване навчання передбачає відсутність зовнішніх втручань у процес корекції синаптичних ваг. Значення ваг коректується автоматично, ефективність мережі контролюється внутрішніми алгоритмами. Для адаптації ваг використовуються спеціальні навчальні функції. Інформація щодо архітектури і організації мережі та критерії оцінки її ефективності мають бути закладені в алгоритми роботи мережі і навчальні правила [67].

1.3.6. Оцінка ефективності застосування нейронних мереж у порівнянні з традиційними методами

З метою порівняння ефективності класичних та нейромережових методів обробки температурних профілів, авторами роботи [38] створено нейромережовий класифікатор. Для навчання мережі застосовувалась навчальна вибірка, що складалася із зразків температурних профілів в точках дефектних і бездефектних зон. Загальний обсяг навчальної вибірки становив 7350 зразків. З них 4070 зразків температурних профілів дефектів, 3280 зразків температурних профілів бездефектних ділянок. Варто відмітити, що для формування вибірки зразків дефектних областей використовувалися тільки ті дефекти, які найбільш впевнено видні на оптимальній термограмі. За результатами роботи НМ для кожного пікселю термограми встановлювала відповідний клас – дефектний (1) або бездефектний (0).

В роботі відзначено високу точність роботи мережі та відсутність артефактів на зображенні. На відміну від класичних методів, форма виявлених дефектів була ближчою до дійсної. НМ продемонструвала високу завадостійкість, оскільки на бінарній карті відсутні впливи нерівномірного нагріву або інші артефакти. Побудова бінарної карти відбулася з високою точністю в автоматичному режимі без додаткових операцій, що демонструє перевагу нейромережових технологій перед іншими методами цифрової обробки термограм.

З метою кількісної оцінки результатів застосування розглянутих методів були розраховані відносні похибки визначення розмірів дефектів. Також отримані значення критерію Танімото, який застосовується в теорії розпізнавання образів для визначення якості розпізнавання [68]. Критерій Танімото розраховується за формулою:

$$T = \frac{N_{r.d.} - N_{m.d.}}{N_{r.d.} - N_{f.d.}} \cdot 100\%, \quad (1.14)$$

де $N_{r.d.}$, $N_{m.d.}$, $N_{f.d.}$ – кількість правильно визначених, пропущених та визначених хибно дефектних точок на термограмі відповідно. Цей критерій можна використовувати для порівняння ефективності різних методів обробки термограм тільки в тому випадку, якщо заздалегідь відомі параметри і місцезнаходження дефектів у зразку. Основною особливістю критерію Танімото є використання одночасно пропущених дефектних точок та точок, які були хибно визначені як дефектні. Це дозволяє пов'язати даний критерій з вірогідністю контролю. Значення $T=100\%$ можливе лише в тому випадку, коли вірогідність коректного виявлення дефектів $P_{c.d.}=100\%$ та вірогідність хибного розпізнавання $P_{f.a.}=0$. Отже, високі значення критерію Танімото свідчать про високу достовірність результатів теплового неруйнівного контролю. Відповідно, зниження значень даного критерію свідчить про погіршення достовірності контролю. Простота розрахунків робить критерій Танімото зручним показником для порівняння та оцінки методів обробки послідовностей термограм.

Результати кількісної оцінки методів обробки термограм дозволили зробити наступні висновки. Завдяки методу аналізу Фур'є існує можливість виявити образи усіх присутніх на термограмах структур. Для збільшення результативності даного методу вимагається значне число термограм у послідовності та їх накопичення протягом короткого часу. Метод неефективний для побудови бінарних карт.

Обробка послідовності термограм методом вейвлет-перетворення також дозволила виявити всі приховані елементи на термограмах. На відміну від Фур'є-аналізу, вейвлет-перетворення надає змогу отримати більш чітке зображення з меншою кількістю сторонніх завад. Метод має аналогічні до Фур'є аналізу переваги та недоліки. Водночас, застосування вейвлетів потребує значних обчислювальних витрат. Можливості автоматизації та класифікації дефектів із використанням даного методу не доведені та потребують додаткових досліджень.

Статистичний метод аналізу головних компонент є ефективним способом обробки даних активного ТНК. Зменшення розмірності початкових даних є головною перевагою методу. Існує теоретична можливість класифікації дефектів із використанням МАГК, проте дослідження за даним напрямом відсутні. Бінарні карти, отримані за допомогою даного методу, дозволяють підвищити ефективність виявлення прихованих дефектів.

Частково вирішити задачі теплової дефектометрії дозволяє метод динамічної теплової томографії. Початкова послідовність термограм замінюється лише двома зображеннями, які у випадку наявності калібрувальних залежностей надають змогу побудувати теплові томограми. Ефективність методу значно залежить від вибору еталонної точки, що в умовах нерівномірного нагріву викликає значні труднощі. Метод вимагає імпульсного нагріву та високої кадрової частоти запису термограм. Алгоритми методу призначені для побудови бінарних карт та теплових томограм, однак не дозволяють проводити автоматичну класифікацію дефектів.

Найбільшу ефективність для обробки термограм мають нейронні мережі. Це підтверджується на якісному та кількісному рівнях. Застосування НМ дозволяє автоматично побудувати бінарні карти, класифікувати дефекти та визначити їх параметри із підвищеною відносно класичних методів точністю. Недоліком є

необхідність у наявності об'ємної бази навчальних даних та відсутність єдиного чіткого підходу щодо визначення оптимальної архітектури і параметрів мереж.

1.4. Огляд існуючих робіт за напрямом дослідження

Питанням аналізу послідовностей термограм з метою автоматизованого виявлення, класифікації дефектів та визначення їх характеристик присвячено досить обмежену кількість наукових робіт. Початкові дослідження були спрямовані на здійснення дефектометрії шляхом вирішення обернених задач ТНК. З розвитком сучасних технологій цифрової обробки даних, тенденції розвитку змістились в область застосування новітніх методів та систем на базі НМ.

Дослідження однозначності обернених задач по визначенню параметрів багат шарових середовищ почалося з роботи [69], в якій розглянуто задачу відновлення геоелектричного розрізу. В роботі [70] доведена теорема однозначності визначення ефективних параметрів середовища, схильного до теплового поверхневого впливу. У перерахованих джерелах об'єктом дослідження є багат шарова структура з ідеальним контактом на межах розділу шарів. У роботі [71] доведені теореми однозначності для багат шарового середовища з неідеальним контактом. Далі вирішуються обернені задачі по визначенню теплопровідностей і глибин залягання тонких теплопроникних дефектів. Для процесу ТНК, який проводиться з метою виявлення розшарувань в теплоізоляційних пластинах, отримані наближені рішення.

Дослідження [72] та [73] присвячені розробці методики розпізнавання тривимірних дефектів методом оцінки ступеня подібності поверхні теплового поля ОК з наявними тривимірними поверхневими моделями, які отримано шляхом чисельного моделювання тривимірної задачі теплопровідності. Водночас сама тривимірна модель ОК в початковий момент дослідження передбачає відсутність дефектів. Дана методика діагностики тривимірних дефектів складається з методики розпізнавання контурів дефектів, яка вирішує задачу наближеного знаходження з заданою точністю форми дефектів та їх місцезнаходження на площині, та методики розпізнавання тривимірних дефектів, в тому числі КМ, яка заснована на

чисельному розв'язанні тривимірної задачі теплопровідності і вирішенні задачі розпізнавання дефекту, який має максимальну схожість з реальним.

В роботі [74] представлена коротка історія та сучасний стан досліджень у лабораторії теплового контролю Томського політехнічного університету. Основний акцент лабораторних досліджень – вдосконалене моделювання (аналітичне та числове) та цифрова обробка даних ТНК, включаючи застосування перетворення Фур'є та вейвлет-аналізу, нейронні мережі, кореляційний аналіз, динамічну теплову томографію та інші методи ТНК. У даній роботі описані експериментальні випробування, результати практичного застосування розробок в авіаційній та енергетичній галузях, а також напрями майбутніх досліджень.

Авторами роботи [75] було проведено дослідження можливостей застосування нейронних мереж для контролю виробів із багат шарових матеріалів. Побудована в результаті бінарна карта дефектів не поступалась за якістю аналогічним картам, отриманим традиційними методами. Переваги використання НМ в зазначеній роботі продемонстровані лише на якісному рівні. Зазначається та доводиться можливість використання нейромережевих класифікаторів.

В роботі [76] нейронна мережа застосовується для побудови карт дефектів та класифікації дефектів за глибиною залягання. Переваги застосування НМ показані лише на якісному рівні. Відсутні дослідження ефективності НМ в задачах визначення глибини або товщини дефектів, впливу архітектури мережі або якості навчальної вибірки на результат роботи тощо.

Робота [77] присвячена дослідженню застосування НМ для контролю композитів. Наведено результати обробки експериментальних даних з контролю вуглепластика за допомогою двох нейронних мереж, що забезпечують як якісне виявлення прихованих дефектів, так і елементи дефектометрії. Перша нейромережа призначена для виявлення дефектних зон, а за допомогою другої здійснюється класифікація дефектів за глибиною залягання. Доведена висока ефективність НМ в обох типах задач.

Авторами роботи [78] пропонується метод активного ТНК з використанням штучних нейронних мереж для оцінки глибини залягання внутрішніх дефектів за

значеннями температурного контрасту. Результати експериментів підтвердили ефективність методу визначення глибини дефектів. В роботі використовувалось комп'ютерне моделювання імпульсної термографії алюмінієвого зразка. Для визначення глибини дефектів застосовувалась стандартна техніка обробки термограм за допомогою штучних НМ. За результатами досліджень, похибка вимірювання глибини залягання не перевищила 3%. Варто зазначити, що матеріал ОК в даній роботі однорідний, а експеримент на реальних зразках не проводився.

В роботі [79] проведено дослідження ефективності методу визначення глибини залягання дефектів КМ з використанням НМ. Встановлено, що анізотропні властивості та складність виготовлення КМ ставлять під сумнів існуючі традиційні методи ТНК. Авторами представлений і реалізований новий алгоритм, заснований на використанні НМ для визначення. Процедура контролю передбачає трикоординатне лінійне сканування ОК, яке використовується для безперервного проходження керованого нагрівача в тандемі з тепловізором. У дослідженні проводиться комп'ютерне моделювання описаної процедури. Навчену НМ перевіряли в задачах визначення глибини дефектів на тестових наборах даних. Точність вимірювання склала 97,5 % для дефектів глибиною до 1 мм. Також проведено експериментальну перевірку ефективності роботи НМ, яка показала похибку до 10% під час визначення глибини залягання дефектів на рівні 0,5 мм.

Загалом, традиційні методики визначення параметрів дефектів базуються на виявленні за тепловим полем однієї з поверхонь ОК конкретних розташувань та форм дефектів [80]. Для вирішення цієї задачі необхідно, щоб до початку вимірювань вже були визначені геометричні характеристики дефектів на площині, а саме центри тяжіння теплових відбитків дефектів та їх контури на площині. Також необхідна наявність геометричної моделі ОК без дефектів. Теплове поле має бути отримано за допомогою тепловізора та спроектовано на поверхню геометричної моделі ОК. Мають бути відомі характеристики ОК та умови запису термограм. Можливість автоматичної класифікації дефектів при цьому не описується.

Аналіз існуючих публікацій показав, що застосування сучасних інтелектуальних систем дозволяє вирішувати вищенаведені задачі з більшою

ефективністю. Існуючі дослідження доводять перспективність використання НМ для класифікації дефектів та дефектометрії. Похибка вимірювання глибини дефектів традиційними методами сягає 7-10 %, в той час як нейронні мережі дозволяють знизити її до рівня 2,5-3 %. Водночас, в існуючих роботах не наводиться кількісна оцінка ефективності визначення товщини (розкриву) дефектів із застосуванням НМ. В основному, автори робіт фокусуються на вирішення однієї конкретної задачі, в той час як сучасний підхід вимагає комплексного автоматизованого аналізу ОК з метою якомога більш повного його опису. Наразі відсутні системи, які на практиці реалізують одночасне вирішення задач класифікації дефектів та дефектометрії в автоматизованому режимі. Отже, це питання є недостатньо дослідженим та невирішеним.

1.5. Постановка мети та задач дослідження

На базі проведеного аналітичного огляду стану розвитку сучасних методів теплової дефектоскопії та дефектометрії сформульовано мету та поставлено задачі дослідження.

Метою роботи є автоматизація процесу активної теплової дефектоскопії та дефектометрії із застосуванням нейромережових технологій, що забезпечуватиме підвищення інформативності, достовірності та ефективності контролю виробів із багат шарових матеріалів.

Для досягнення поставленої мети в дисертації вирішуються наступні завдання:

1. Проаналізувати сучасний стан розвитку методів активного теплового неруйнівного контролю, визначити основні проблеми багатопараметрового АТНК багат шарових матеріалів та обґрунтувати застосування нейронних мереж для їх розв'язку. Обґрунтувати вибір типу та архітектури НМ.

2. Удосконалити метод оцінки характеристик дефектів при активному тепловому контролі для забезпечення автоматизованого вирішення задач класифікації дефектів, визначення їх глибини залягання і розкриву, а також побудови теплових томограм з метою підвищення інформативності та

достовірності контролю. Розробити необхідне алгоритмічне та програмне забезпечення.

3. Провести комп'ютерне моделювання процесу АТНК зразків матеріалів з різною структурою. Обробити отримані дані за допомогою класичних методів та удосконаленого методу на базі нейронних мереж.

4. Дослідити вплив параметрів НМ та характеристик набору вхідних даних на ефективність оцінки параметрів дефектів.

5. Розробити та виготовити дослідні зразки з багатошарових матеріалів та експериментальний стенд для проведення АТНК із використанням системи на основі удосконаленого методу.

6. Експериментально дослідити ефективність удосконаленого методу в задачах багатопараметрового АТНК виготовлених зразків. Порівняти результати обробки експериментальних даних класичними методами та удосконаленим методом із використанням НМ.

Висновки до розділу 1

У першому розділі отримано наступні результати:

1. Проаналізовано проблеми контролю виробів із багатошарових і композиційних матеріалів, які є найбільш складними об'єктами для теплового контролю. Обґрунтовано необхідність вдосконалення систем теплового неруйнівного контролю виробів з КМ.

2. Проаналізовано інформативні параметри активного теплового контролю, встановлено наявність їх сильного взаємозв'язку, що ускладнює класифікацію дефектів та дефектометрію. Обґрунтовано проблеми вирішення обернених задач теплового контролю, зокрема, неоднозначність розв'язку та низьку адаптивність.

3. Проведено порівняльний аналіз традиційних методів обробки термограм. Застосування розглянутих методів дозволяє в ряді випадків покращити співвідношення сигнал/шум, виявити на зображеннях контури прихованих дефектів, побудувати бінарні карти. Однак, існуючі методи мають низьку

завадостійкість, що робить їх малоефективними в умовах значної нерівномірності нагріву або наявності інших завад. Можливості автоматизованої класифікації дефектів та визначення їх розкриву традиційними методами недостатньо вивчені.

4. Обґрунтовано можливість застосування штучних нейронних мереж у якості класифікаторів дефектів та засобів визначення їх параметрів. Доведено підвищену ефективність нейромережевих систем у порівнянні з традиційними методами. Встановлено перспективність подальшого розвитку систем теплового контролю на базі нейромереж.

5. В результаті аналізу літературних джерел встановлено необхідність проведення експериментальних досліджень роботи систем ТНК на базі НМ. Сформульовано науково-технічну задачу розробки і дослідження автоматизованої системи аналізу даних теплового контролю із використанням нейромережевих технологій для визначення характеристик дефектів, що забезпечуватиме підвищення інформативності, ефективності та достовірності ТНК.

РОЗДІЛ 2

РОЗРОБКА МЕТОДУ АВТОМАТИЗОВАНОЇ ОБРОБКИ ПОСЛІДОВНОСТІ ТЕРМОГРАМ ІЗ ВИКОРИСТАННЯМ НЕЙРОМЕРЕЖЕВИХ ТЕХНОЛОГІЙ

2.1. Реалізація удосконаленого методу визначення характеристик дефектів за результатами активного теплового контролю

Тенденції розвитку ТНК ставлять наступні вимоги до систем контролю:

- високий рівень автоматизації;
- висока інформативність, швидкодія та продуктивність контролю;
- універсальність та висока адаптивність;
- висока достовірність контролю та точність дефектометрії;

Для виконання даних вимог необхідне використання сучасного апаратного обладнання та програмного забезпечення [81]. Водночас, загальна схема проведення активного теплового контролю залишається незмінною. Об'єкт контролю піддається дії джерела теплового навантаження. Всередині твердого тіла теплова енергія розповсюджується в усіх напрямках завдяки процесу дифузії. В разі наявності прихованих дефектів теплові потоки всередині ОК перерозподіляються, що призводить до виникнення на його передній та задній поверхнях специфічних температурних аномалій. Температурне поле ОК спостерігається та реєструється за допомогою тепловізора. Температурні сигнали, представлені у вигляді термограм, передаються автоматизованій системі обробки даних на ПК для виявлення дефектів та визначення їх параметрів [82].

Існує дві можливі схеми активного ТНК в залежності від взаємного розташування джерела нагріву та тепловізора відносно ОК. Так, в односторонній схемі джерело нагріву та тепловізор розташовані з одного боку відносно ОК, у двосторонній вони розміщені з різних боків відносно ОК.

Вибір схеми контролю, характеристики джерела нагріву та тепловізійного обладнання значно впливають на результат діагностики. Від даних факторів

напряму залежить ефективність традиційних методів обробки послідовностей термограм. Це призводить до зниження універсальності систем контролю, які використовують стандартні алгоритми обробки даних. Зокрема, зміна ОК, джерела нагріву або тепловізора в багатьох випадках ведуть до необхідності повного перерахунку параметрів системи. Застосування сучасних методів обробки даних ТНК на базі НМ дозволяє додавати інформацію про нові ОК або враховувати зміни умов контролю без втрати попередніх даних. Оскільки вся інформація щодо набутого мережею досвіду міститься в значеннях синаптичних ваг, перенавчання системи у випадку контролю нових об'єктів або появи нових типів дефектів не призведе до необхідності зміни алгоритмів обробки даних.

Загальна схема реалізації удосконаленого методу визначення характеристик дефектів наведена на рис. 2.1. Завдяки вищезазначеним перевагам, система є універсальною і може використовуватись для обох схем контролю та незалежно від характеристик джерела нагріву, тепловізора або параметрів ОК. Робота нейромережевих модулів та інтерфейс користувача докладно описуються далі.

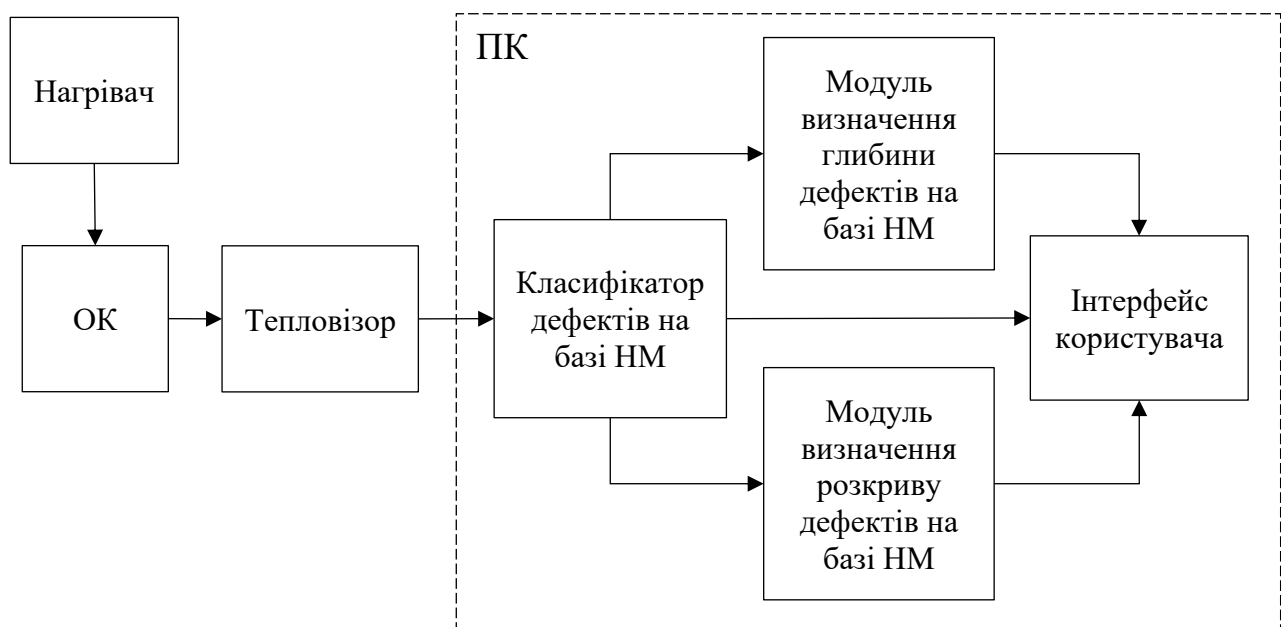


Рис. 2.1. Структура запропонованої системи аналізу результатів активного теплового контролю

2.2. Вибір типу та архітектури нейромережевих модулів

В розробленій системі нейронна мережа має вирішувати завдання як класифікації дефектів, так і визначення глибини їх залягання та розкриття. У першому випадку вирішується задача розпізнавання образів, у другому – побудови моделі регресії. На сучасному етапі розвитку існує велика кількість різних типів нейронних мереж, що застосовуються в широкому колі задач. Вибір типу НМ є важливим завданням, оскільки кожна модель мережі оптимізована для вирішення певних профільних задач. В тепловому контролі найбільш дослідженими є класифікатори на базі багат шарових мереж зворотного поширення помилки. В той же час, для обробки термограм застосовуються згорткові нейронні мережі. Для аналізу температурних профілів можуть використовуватись і мережі, які використовують алгоритми самонавчання, наприклад, мережі адаптивної резонансної теорії [83].

Специфічними особливостями теплового контролю, які необхідно врахувати для вибору типу нейронної мережі, є:

- необхідність наявності зразків дефектів для кожного класу об'єктів;
- великий обсяг оброблюваних даних;
- аналоговий вектор вхідних даних;
- система повинна розпізнавати велику кількість класів дефектів з можливістю додавання в класифікацію нових дефектів (дилема стабільності-пластичності);
- необхідність високої заданої точності розпізнавання та визначення параметрів дефектів;
- висока швидкість роботи системи, робота в режимі реального часу.

Під час вибору типу НМ враховуються особливості вхідного набору даних. Структура мережі повинна бути обрана так, щоб вона максимально ефективно використовувала вхідні дані. Похідні властивості системи, такі як точність і швидкість обробки, можуть бути забезпечені налаштуванням мережі.

2.2.1. Аналіз типів нейронних мереж, що можуть бути застосовані для обробки даних теплового контролю

Згорткові нейронні мережі. Згорткова нейронна мережа (англ. Convolutional Neural Network) – це окрема архітектура штучної НМ, яка імітує особливості зорової кори головного мозку та складається з декількох багатовимірних прошарків і призначена для ефективного розпізнавання складних зображень. Вперше така модель була запропонована Яном Лекуном в 1998 році [84] і призначалася для розпізнавання рукописних символів. Особливість запропонованої Лекуном моделі нейронної мережі полягає у введенні в архітектуру багатошарового персептрона згорткових прошарків, в яких кожен нейрон пов'язаний тільки з невеликою групою нейронів попереднього прошарку. Така будова дозволяє виділяти на оригінальному зображенні примітивні особливості, а на наступних прошарках мережі об'єднувати виділені ознаки, отримуючи все більш складні елементи. Таким чином детектуються складні об'єкти на зображеннях. Схема ЗНМ показана на рис. 2.2.

Топологія ЗНМ використовує ідею розділення синаптичних ваг. Це означає, що для великої кількості зв'язків використовується порівняно невеликий набір ваг. Ці набори ваг також називають ядрами. Вікно матриці ваг проходить по попередньому прошарку, повертаючи результат від математичної операції згортки. Суть цієї операції полягає в тому, що кожен фрагмент зображення поелементно множиться на матрицю (ядро) згортки, результат сумується та записується в аналогічну позицію вихідного зображення [85].




Рис. 2.2. Схема згорткової нейронної мережі

Чергування прошарків згортки і підвибірки дозволяє отримати карти ознак у вигляді чисельних векторів або навіть скалярів. Чергування шарів дозволяє складати карти ознак з карт ознак, що на практиці означає здатність розпізнавання складних ієрархій ознак. Перед виходом мережі знаходиться повнозв'язний прошарок, в якому нейрони пов'язані з усіма нейронами попереднього прошарку як в класичних нейронних мережах. Даний елемент необхідний для класифікації даних. Значення нейронів вихідного прошарку показують ступінь ймовірності приналежності вхідного зображення до певного класу.

У той час як згорткові мережі є ефективним методом для обробки зображень, на даний момент це фактично єдина задача, для вирішення якої вони придатні. Також проблему викликає структура внутрішніх прошарків: за великої кількості варійованих параметрів (таких як кількість прошарків, крок дискретизації, розмір ядра згортки тощо) немає повного уявлення про те, як ці параметри впливають на результат обчислення. Внаслідок цього оптимізація параметрів мережі відбувається в основному емпіричним шляхом.

Багат шарові мережі прямого розповсюдження зі зворотним поширенням помилки. Топологія мереж прямого розповсюдження (англ. feedforward) зі зворотним поширенням помилки (англ. backpropagation) була розроблена на початку 1970-х років декількома незалежними авторами, такими як Вербор, Паркер, Румельгарт, Хінтон та Вільямс. На даний час, парадигма прямого розповсюдження є найбільш популярною та ефективною, а проста модель навчання зі зворотним поширенням помилки використовується для багат шарових мереж будь-якої складності. Даний тип мереж використовується у різних класах задач і є основою для побудови НМ з різними архітектурами та методами навчання [86].

Типова мережа прямого розповсюдження має вхідний прошарок, вихідний прошарок та принаймні один прихований прошарок. Теоретично, обмежень відносно числа прихованих прошарків не існує, але на практиці застосовують один або два. Схема мережі повністю ідентична стандартній багат шаровій мережі. В якості методу навчання застосовуються алгоритми зворотного поширення помилки.

Мережі адаптивної резонансної теорії. Мережі АРТ являють собою векторний класифікатор [87]. Вхідний вектор класифікується в залежності від того, на який із раніше запам'ятованих мережею еталонних образів він схожий. Рішення щодо класифікації вхідного вектору АРТ виражає у формі збудження одного з нейронів прошарку розпізнавання. Якщо вхідний вектор не відповідає жодному із запам'ятованих образів, створюється нова категорія (виділяється новий нейрон та запам'ятовується новий вектор), яка відповідає вхідному вектору. Якщо визначено, що вхідний вектор схожий на один з раніше запам'ятованих векторів за визначеним критерієм подібності, еталонний вектор в пам'яті мережі буде змінюватися (навчатися) під впливом нового вхідного вектора так, щоб стати більш схожим на даний вхідний вектор. Приклад АРТ-структури представлений у роботі [6], схема мережі зображена на рис. 2.3.




Рис. 2.3 Схема нейронної мережі АРТ-2

Особливість структури АРТ-2 полягає в тому, що вхідний прошарок складається з 6 підпрошарків ($W_i, X_i, V_i, U_i, P_i, Q_i$), кожен з яких містить N нейронів. Наявність цих підпрошарків обумовлено завданням нормалізації вхідних значень. Результатом роботи мережі є або номер «нейрона-переможця» Y_i , який пройшов

перевірку на близькість за критерієм $R_i \geq \rho$, тобто факт розпізнавання вектора і його віднесення до відомого класу (кластеру) об'єктів, або повідомлення про відсутність кластера для даного вектора і створення такого кластера [88].

Мережі й алгоритми АРТ-2 зберігають пластичність, необхідну для вивчення нових класів об'єктів, у той же час запобігаючи зміні раніше запам'ятованих класів. Також мережі АРТ-2 дозволяють виконувати аналіз форми отриманих інформаційних сигналів, тобто без попередньої обробки вхідних даних формувати набір діагностичних ознак, що значно розширює область їх застосування. АРТ-мережі можуть використовуватись для вирішення таких задач НК, як кластерний аналіз, класифікація дефектів ОК, розпізнавання образів тощо [89].

АРТ-2 не чутлива до порядку пред'явлення вхідних векторів, має високу швидкодію роботи, та високу достовірність класифікації даних. До того ж АРТ-2 має властивість до самостійного виправлення помилок класифікації після певної кількості циклів повторного пред'явлення навчальної вибірки [90].

2.2.2. Обґрунтування вибору багат шарової мережі прямого розповсюдження зі зворотним поширенням помилки

На сьогоднішній день в літературних джерелах не проводився аналіз ефективності різних типів НМ в тепловому контролі. Тому вибір оптимального типу мережі для вирішення задач класифікації дефектів і дефектометрії варто проводити на основі відомих характерних особливостей існуючих мереж та типів даних, з якими вони працюють.

Актуальним завданням теплового неруйнівного контролю є не лише виявлення та класифікація прихованих дефектів, але і визначення їх параметрів, таких як розмір, форма та глибина залягання. Термограма в оптимальний момент часу є двовимірним зображенням температурного поля розмірністю $M \times N$ і дає інформацію лише про розмір та місцезнаходження дефектів. Неможливо оцінити глибину дефектів використовуючи лише одне зображення. Для визначення глибини дефектів при проведенні активного теплового контролю записують послідовність термограм, яка показує динаміку зміни теплового поля ОК в часі. У

подальшому аналізують температурні профілі $T(i, j, \tau)$ – функції зміни температури в часі для кожної точки (пікселю) термограми з координатами $(i; j)$. Таким чином, для побудови теплових томограм аналізуються не 2D термограми, а одновимірні вектори, що містять температурні профілі кожного пікселю. Кожна термограма у послідовності містить температурне значення кожного пікселю $(i; j)$ в даний момент часу τ . В результаті послідовного запису температурних значень пікселю у кожний момент часу вимірювання (в кожній термограмі) отримують вектор його температурного профілю. Довжина такого вектору буде рівною кількості термограм у послідовності, яка була записана під час проведення контролю [91].

Згорткові нейронні мережі мають високу ефективність в задачах розпізнавання образів та обробці зображень. Потенційно, даний тип НМ може бути використаний для класифікації дефектів, які чітко проявляються на оптимальних термограмах. Водночас, в активному ТНК найбільшу інформативність мають температурні профілі. На сьогоднішній день відсутні дослідження застосування ЗНМ в задачах дефектометрії, а початкова спрямованість даного типу мереж на задачі розпізнавання образів на зображеннях роблять питання їх застосування в складі системи аналізу даних теплового контролю із використанням удосконаленого методу визначення характеристик дефектів ще більш дискусійним.

Мережі АРТ також ефективно використовуються в задачах розпізнавання образів та кластерного аналізу. В той же час, недоліком є необмежене збільшення числа нейронів в процесі функціонування мережі. В разі наявності шумів виникають проблеми, пов'язані з неконтрольованим зростанням числа зразків [92]. Особливості структури мереж АРТ не дозволяють використовувати їх для дефектометрії, оскільки топологія мереж АРТ призначена для вирішення задач класифікації, а не регресії, що ускладнює їх використання в активному ТНК [93].

Багатошарові мережі прямого розповсюдження зі зворотним поширенням похибки є найбільш універсальними та використовуються як в задачах класифікації, так і регресії. Відомо, що даний тип НМ має найкращі апроксимуючі властивості, і саме тому їх повнозв'язані прошарки входять до складу топологій багатьох інших мереж [94]. В тепловому контролі мережі прямого розповсюдження

можуть застосовуватись як для обробки термограм і класифікації дефектів, так і для аналізу температурних профілів і дефектометрії. Завдяки даній особливості значно спрощується процес підготовки множини навчальних даних, оскільки їх формат буде однаковим для будь-якої архітектури.

Зворотне поширення помилки є першим ефективним алгоритмом навчання багат шарових нейронних мереж. Це один з найпопулярніших алгоритмів навчання, з його допомогою вже вирішені і вирішуються численні практичні завдання [95]. Однак, багатокритеріальна задача оптимізації в методі зворотного поширення розглядається як набір однокритеріальних – на кожній ітерації відбуваються зміни значень параметрів мережі, що поліпшують роботу лише з одним прикладом навчальної вибірки. Такий підхід знижує швидкість навчання.

В роботі [96] доводиться можливість застосування нейронних мереж прямого розповсюдження в активному ТНК. Автором розроблено НМ з одним бінарним виходом для використання у тепловій дефектоскопії. Для здійснення теплової дефектометрії та побудови теплових томограм використовується мережа того самого типу, але з довільним числом виходів. Ефективність розроблених мереж перевірена для випадку обробки даних теплового контролю стандартного зразка з вуглепластику. Комбінована томограма стандартного зразка побудовано шляхом поєднання томограм п'яти окремих прошарків, які отримано в результаті роботи нейронної мережі. Результати дослідження показали, що використання НМ прямого розповсюдження дозволяє ефективно здійснювати як теплову дефектоскопію, так і дефектометрію. Отже, даний тип НМ є найбільш оптимальним для застосування в складі системи аналізу даних теплового контролю із використанням удосконаленого методу визначення характеристик дефектів.

2.2.3. Вибір архітектури обраної нейронної мережі

За допомогою багат шарових нейронних мереж прямого розповсюдження можлива побудова регресійних моделей будь-яких функцій. Складність функції визначається числом прихованих прошарків та числом нейронів у кожному із них.

Тому під час побудови моделі мережі важливим є визначення оптимальної кількості прошарків та числа нейронів [97].

На сьогоднішній день не проводився аналіз впливу зазначених параметрів мережі на ефективність обробки даних в активному ТНК. Тому для визначення архітектури нейромережових модулів системи аналізу даних теплового контролю із використанням удосконаленого методу визначення характеристик дефектів необхідно користуватися загальними правилами та рекомендаціями [98]:

1. Кількість нейронів у вхідному прошарку відповідає розмірності вектора вхідних даних. Число нейронів вихідного прошарку залежить від задачі, яку вирішує мережа. В задачах регресії на виході НМ зазвичай один нейрон. В завданнях класифікації кількість нейронів відповідає кількості класів (станів ОК або типів дефектів).
2. Кількість нейронів у прихованих прошарках $n_{\text{прих}}$ визначається емпірично. Часто необхідну кількість нейронів обчислюють як $n_{\text{прих}} = n_{\text{вх}} + n_{\text{вих}}$, де $n_{\text{вх}}$ та $n_{\text{вих}}$ – число нейронів у вхідному та вихідному прошарках відповідно.
3. Збільшення складності прихованих взаємозв'язків у вхідних даних, а також підвищення точності класифікації вимагає збільшення числа нейронів.
4. Якщо вхідний образ містить декілька рівнів діагностичних ознак, або функція складається з кількох етапів, необхідне відповідне збільшення числа прихованих прошарків. В іншому випадку збільшення кількості прошарків може призвести до погіршення апроксимуючих властивостей мережі.

Враховуючи зазначені рекомендації, можна зробити висновок, що кількість прихованих прошарків НМ для задач теплової дефектоскопії та дефектометрії не має перевищувати двох. Кількість нейронів визначається емпірично.

2.3. Розробка алгоритмів формування навчальної множини вхідних векторів

Особливо важливим етапом навчання НМ є формування навчальної вибірки. Від повноти та якості множини вхідних векторів для навчання мережі на пряму залежить ефективність її роботи. Тому на перший план виходить необхідність забезпечення репрезентативності навчальної вибірки.

Репрезентативність – відповідність характеристик вибірки характеристикам популяції або генеральної сукупності в цілому [99]. Репрезентативність визначає, наскільки можна узагальнювати результати дослідження із залученням певної вибірки на всю генеральну сукупність, з якої вона була зібрана.

В контексті аналітичних технологій під репрезентативністю вихідних даних розуміють наявність достатньої кількості різноманітних навчальних прикладів, що відображають правила і закономірності, які повинні бути виявлені моделлю в процесі навчання [100]. Вона має три аспекти [101]:

1. Достатність – число навчальних прикладів має бути достатнім для навчання. Для нейронної мережі необхідно, щоб число навчальних прикладів було в кілька разів більше, ніж число ваг зв'язків між нейронами. В іншому випадку модель може не отримати здатності до узагальнення. Крім того, розмір вибірки повинен бути достатнім для формування навчальної і тестової множин вхідних векторів;
2. Різноманітність – велике число різноманітних комбінацій входів-виходів в навчальних прикладах. Здатність НМ до узагальнення не буде ефективною, якщо кількості прикладів достатню, але всі вони однакові, тобто представляють лише частину класів, характерних для початкової множини;
3. Рівномірність представлення класів – приклади різних класів повинні бути представлені в навчальній вибірці приблизно в однакових пропорціях. Якщо один з класів буде переважати, то це може привести до «перекосу» в процесі навчання моделі, і даний клас буде визначено моделлю як найбільш ймовірний для будь-яких нових спостережень [102].

Зазвичай, вхідні навчальні вектори вибираються із наявної сукупності прикладів випадковим чином. Однак метод випадкового вибору не може гарантувати повне забезпечення репрезентативності. Елемент випадковості, особливо за досить великої кількості класів може вносити значні похибки, в тому числі такі, які призводять до нерепрезентативності навчальної вибірки.

Іншою складністю під час навчання НМ є так зване перенавчання, яке означає занадто точне відтворення мережею значень відповідей для вхідних навчальних

векторів. В такому випадку мережа втрачає свої узагальнюючі властивості [103]. Причиною виникнення перенавчання є занадто ускладнена архітектура НМ, надмірно тривале навчання або нерепрезентативна навчальна вибірка.

Виникнення перенавчання також пов'язане з випадковим характером вибірки навчальних векторів. В такому випадку, на початку навчання помилка мережі зменшується. Синаптичні ваги налаштовуються для мінімізації функції помилки, величина якої залежить від особливостей множини навчальних векторів. Підлаштування ваг відбувається під особливості навчальної множини, яка є лише частиною загального набору даних. Це призводить до зниження точності класифікації або прогнозування.

З метою вирішення проблеми перенавчання навчальну вибірку розділяють на дві або три множини (навчальну і тестову; іноді виділяють ще валідаційну множину). Основне навчання відбувається на навчальній підмножині. Тестова підмножина призначена для перевірки ефективності навченої мережі. Дані підмножини не мають перетинатися [104].

На навчальній множині відбувається покрокова мінімізація функції помилки шляхом зміни параметрів мережі, тому величина помилки на ній постійно знижується. Зменшення помилки одночасно спостерігається і на тестовій множині, однак в певний момент цей процес порушується і помилка на тестовій множині починає зростати. Водночас на навчальній множині продовжується зниження похибки. Момент виникнення даної розбіжності є початком перенавчання мережі. Таким чином, використання тестової множини є засобом перевірки працездатності НМ на зразках, які не використовувались під час навчання.

2.3.1. Алгоритм формування навчальної множини для класифікації дефектів

Під час навчання нейромережевого класифікатора передбачається, що для кожного вхідного вектора існує парний йому цільовий вектор, що задає необхідний вихід (відповідь) НМ. Разом дані вектори називають навчальною парою. Навчальна вибірка складається з великого числа таких навчальних пар. В задачах класифікації

дефектів у тепловому контролі вхідними навчальними векторами (предикторами) $X_n[n]$ є температурні профілі ділянок ОК. Довжина n вхідного вектора є кількістю термограм в послідовності. Цільовими є вектори $Y_n[m]$, які містять бінарний код, що відповідає номеру класу. Довжина m цільового вектора залежить від кількості класів, яка в свою чергу визначається числом можливих типів дефектів [105].

Першим класом зазвичай є бездефектний стан ОК. У випадку контролю композиційних матеріалів, основними типами дефектів є розшарування, пори, обриви армуючих елементів та сторонні включення. Розшарування та пори за фізичною суттю є порожнинами, заповненими газом, що дозволяє віднести їх до одного типу дефектів. Таким чином, можна виділити три основних класи дефектів. Отже, вектор цілей для конкретного теплового профілю має складатись з чотирьох елементів, які загалом формують код визначеного класу.

Код класу формується наступним чином. Нехай кількість класів $N_{кл} = 4$. Це означає, що вихідний прошарок НМ складається з $m = 4$ нейронів. Значення першого нейрона відповідає величині ймовірності приналежності вхідного зразка до першого класу, який в даному випадку символізує бездефектну ділянку, і є першим елементом $Y_n[1]$, цільового вектора $Y_n[m]$. Наступні три нейрони відповідають певному класу дефектів, та є наступними елементами $Y_n[2...4]$ цільового вектора $Y_n[m]$. Відповідно, в ідеальному випадку код першого класу (бездефектної ділянки) має вигляд $[1\ 0\ 0\ 0]$; код другого класу – $[0\ 1\ 0\ 0]$, код третього класу – $[0\ 0\ 1\ 0]$; код четвертого класу – $[0\ 0\ 0\ 1]$. Дані вектори будуть цільовими для відповідних вхідних векторів температурних профілів. Разом температурний профіль та код класу утворюють навчальну пару.

Для зручності подальшої обробки, два вектори кожної навчальної пари за допомогою операції конкатенації об'єднуються в один навчальний вектор. Після здійснення вибірки необхідних температурних профілів та встановлення навчальних пар і складання навчальних векторів, всі навчальні вектори можна об'єднати в одну матрицю. Кількість рядків у такій матриці відповідає загальній кількості навчальних векторів. Кількість стовпців визначається як довжина вектора навчальної пари. Отримана матриця є навчальною множиною даних.

На наступному етапі відбувається перемішування навчальних векторів у випадковому порядку – рандомізація вибірки. Дана операція необхідна для забезпечення рівномірного порядку представлення навчальних зразків нейронній мережі [106]. Після рандомізації відбувається зворотне розділення навчальних векторів на вхідні вектори та відповідні їм вектори цілей. В результаті зазначених операцій отримується набір рандомізованих навчальних пар.

Далі отримана множина розбивається на дві частини. Перша з них складає 70% від початкової множини і є навчальною. Друга множина складає 30% від початкової і є тестовою. Для підвищення ефективності навчання, половина тестової множини відокремлюється і складає валідаційну множину. Таким чином, початкова множина навчальних даних ділиться на три частини в наступних пропорціях: 70% - навчальна множина, 15% - тестова множина, 15% - валідаційна множина. Схема описаного алгоритму наведена на рис. 2.4.



Рис. 2.4. Загальна схема алгоритму формування множини навчальних векторів

Вибірка навчальних температурних профілів проводиться з множини даних, отриманих за результатами контролю спеціальних тестових зразків з відомими параметрами та типами дефектів. Зразок може бути один або декілька. Чи більше

буде використано різних тестових зразків з різними типами дефектів, тим якісніше буде представлена навчальна вибірка. Крім того, однакові тестові зразки можуть бути проконтрольовані в різних умовах, з використанням різних джерел нагріву та тепловізорів. У випадку обмеженої кількості зразків для отримання навчальної множини може використовуватися комп'ютерне моделювання [107]. Забезпечення різноманітності навчальних даних дозволить уникнути необхідності повторного навчання мережі в разі зміни обладнання або умов контролю.

2.3.2. Алгоритм формування навчальної множини для визначення глибини залягання та розкриття дефектів

Порядок формування множини навчальних векторів у випадку теплової дефектометрії є аналогічним до попередньо розглянутого алгоритму. Головною відмінністю є те, що для визначення глибини залягання або розкриття дефектів вирішується задача регресії (прогнозування), а не класифікації. Це означає, що вихідний прошарок НМ буде містити лише один нейрон, значення якого відповідатиме визначеному параметру дефекта. Таким чином, цільовий вектор для навчального температурного профіля буде містити один елемент, тобто по суті буде скаляром. Навчальна пара буде складатись з температурного профіля та відповідному йому значенню глибини/розкриття дефекта [108].

Задача прогнозування (визначення) параметрів дефектів за фізичним змістом є більш складною, ніж задача класифікації [109]. Це ставить підвищені вимоги як до архітектури мережі, так і до якості множини навчальних даних. Зокрема, діапазон зміни глибини залягання або розкриття дефектів може бути суттєвим, і сягати десятків міліметрів. Однак, у випадку ефективного навчання немає необхідності представлення мережі зразків температурних профілів, що відповідають всім глибинам / розкриттям із діапазону. Завдяки узагальнюючим властивостям, крок зміни глибин залягання / розкриття штучних дефектів у навчальних зразках може становити 0,5...1 мм. Але обов'язковим є представлення зразків температурних профілів, які відповідають границям діапазонів зміни параметрів, що визначаються [110].

Відомий підхід визначення глибини залягання дефектів у вигляді їх класифікації за певними визначеними діапазонами (прошарками) [75]. В такому випадку, процес формування навчальної множини є повністю ідентичним розглянутому вище алгоритмові. Точність визначення глибини дефекту буде залежати від кроку, з яким ОК умовно розбивається на прошарки. Для зменшення похибки необхідно зменшувати величину прошарків, що призводить до відповідного збільшення числа можливих класів. Наприклад, для досягнення точності в 0,1 мм під час контролю об'єкта товщиною 10 мм знадобиться 100 класів. Тому такий підхід не є оптимальним для даної задачі.

2.4. Розробка віртуальних приладів для реалізації системи аналізу даних теплового контролю із використанням удосконаленого методу визначення характеристик дефектів

Сучасний підхід до створення автоматизованих систем передбачає значне спрощення їх структури, уникнення проміжних електронних вузлів та застосування комп'ютерно-інтегрованих технологій для обробки даних. В активному тепловому контролі на сьогоднішній день основними елементами інформаційно-вимірювальної системи є нагрівач, ОК, тепловізор та ПК. Вся обробка результатів контролю здійснюється за допомогою спеціалізованого програмного забезпечення. Концепція віртуальних приладів передбачає реалізацію елементів керування, індикаторів та інструментів обробки безпосередньо на ПК у вигляді комп'ютерної програми, що позбавляє необхідності у виготовленні окремих фізичних приладів. Це значно спрощує проектування автоматизованих систем, підвищує їх надійність, знижує вартість та в цілому розширює можливості та зручність застосування.

2.4.1. Вибір програмного забезпечення для розробки віртуальних приладів

Найбільш розвинутим середовищем для розробки віртуальних приладів є National Instruments LabVIEW – середовище програмування, яке дозволяє використовувати графічне відображення всіх елементів алгоритму замість

традиційного символічного представлення. NI LabVIEW використовується для створення програм загального призначення та систем цифрової обробки даних. У порівнянні з традиційними лабораторними приладами, розроблена в NI LabVIEW система має високу адаптивність та гнучкість. [111].

Створені в NI LabVIEW програми називають віртуальними приладами, оскільки вони подібні реальним традиційним приладам не лише функціонально, а і за зовнішнім виглядом. Передня панель ВП може містити елементи керування, текстові та графічні індикатори та інші об'єкти інтерфейсу користувача. Блок-діаграма ВП є аналогом традиційного програмного коду, що робить віртуальний прилад подібним до звичайної комп'ютерної програми. Середовище також містить широкий набір функцій та бібліотек для цифрової обробки сигналів [112].

Для зручного проектування нейронних мереж та попередньої математичної обробки даних використовується пакет MATLAB – середовище та однойменна високорівнева мова програмування, що використовується для математичного моделювання, чисельних розрахунків та візуалізації даних. Середовище містить значний набір вбудованих інструментів та функцій, які значно спрощують розрахунки і алгоритми. [113].

MATLAB дозволяє створювати, навчати та тестувати нейронні мережі будь-якої архітектури та складності за допомогою модуля NNTool. Модуль містить графічний інтерфейс користувача та дозволяє гнучко налаштовувати як структуру НМ, так і параметри навчання. Високий рівень інтеграції з іншими програмними пакетами дає змогу використовувати код мережі, написаної на мові MATLAB, у складі інших програм та систем, зокрема у ВП NI LabVIEW [114].

Таким чином, порядок роботи з розробленою автоматизованою системою аналізу результатів теплового контролю із використанням удосконаленого методу визначення характеристик дефектів передбачає використання двох основних програмних пакетів для інженерних розрахунків. Для побудови моделі НМ та її навчання використовуються засоби середовища MATLAB, в якому зручно виконується оптимізація архітектури мережі. Отримана в результаті нейронна мережа може бути експортована в середовище NI LabVIEW для роботи в якості

окремого нейромережевого модуля. Варто відмітити, що NI LabVIEW має власні інструменти для розробки нейронних мереж, але на сьогоднішній день вони не є оптимізованими, що призводить до значно меншої швидкості навчання у порівнянні з інструментами MATLAB. Тому наразі доцільне поєднання можливостей обох програмних середовищ для максимально ефективної роботи.

2.4.2. Розробка блок-діаграми віртуальних приладів для реалізації нейромережевих модулів

Розроблена автоматизована система аналізу даних теплового контролю із використанням удосконаленого методу визначення характеристик дефектів складається з трьох нейромережевих модулів. Перший модуль призначений для виявлення та класифікації дефектів, другий – для визначення глибини залягання дефектів, а за допомогою третього оцінюється розкриття дефектів. Така організація є найбільш оптимальною, оскільки кожна нейронна мережа налаштовується для максимально ефективного вирішення конкретного завдання. Об'єднання другого та третього модуля є недоцільним, оскільки в такому випадку мережа буде намагатись пов'язати характерні особливості температурного профіля одразу з двома незалежними параметрами, що є некоректним.

Для інтеграції програмного коду, написаного на мові MATLAB та призначеного для реалізації алгоритму роботи НМ, в NI LabVIEW використовується модуль MathScript Node RT [115]. Даний додаток дозволяє завантажувати та інтерпретувати коди MATLAB всередині віртуального приладу NI LabVIEW, що дає змогу використовувати програми на мові MATLAB як частину блок-діаграми. Такий високий рівень інтеграції двох програмних пакетів дозволив керувати створеними нейромережевими модулями з передньої панелі віртуального приладу, а також використовувати їх у складі єдиної системи обробки даних без додаткової обробки.

Перший нейромережевий модуль, окрім роботи в якості класифікатора, призначений для побудови карти дефектів. Завдяки цьому до наступних модулів передаються не всі температурні профілі термограми, а лише дані із областей, які

містять дефекти. Це значно пришвидшує роботу системи, оскільки в разі зменшується обсяг даних для опрацювання. Водночас, на вхід першого модуля подаються температурні профілі в усіх точках термограми. Відповідями мережі даного модуля є номери класів, до яких відносяться проаналізовані температурні профілі. Наразі система оптимізована для визначення чотирьох класів, які відповідають наступним технічним станам ОК:

- Клас $Y[1]$: бездефектна ділянка;
- Клас $Y[2]$: дефект типу розшарування;
- Клас $Y[3]$: дефект у вигляді включення стороннього металевого матеріалу;
- Клас $Y[4]$: дефект у вигляді включення стороннього неметалевого матеріалу.

Модуль працює інтеративно, на кожному кроці відбувається обробка одного температурного профіля. Вхідні вектори передаються до модуля послідовно. Процес починається з верхнього лівого кута термограми, наступні температурні профілі подаються по чергові у напрямку зліва направо, зверху вниз. Останнім до мережі надходить температурний профіль із правого кута нижньої сторони термограми. На цьому робота першої НМ завершується. Отримані відповіді накопичуються у вигляді одновимірного масиву на вихідному терміналі структури MathScript Node, звідки передаються на пост-обробку після повного завершення роботи нейромережевого модуля.

Блок-схема алгоритму роботи модуля нейромережевого класифікатора наведена на рис. 2.5. За сигналом старту робота модуля розпочинається з імпорту синаптичних ваг та інших параметрів навченої нейронної мережі. Отримані дані та масив вхідних векторів передаються до циклу, в якому безпосередньо реалізована робота мережі. Код на мові MATLAB, який описує роботу мережі, інтегровано до ВП за допомогою структури MathScript Node.

На першому етапі здійснюється нормалізація та масштабування вхідних даних. Діапазон амплітуд вхідних даних зводиться до границь $[-1...1]$. Дана процедура є стандартною та необхідна для правильної роботи мережі [116]. Нормалізація проводиться за формулою:

$$in_{prep} = \frac{(y_{max} - y_{min}) \cdot (in - x_{min})}{(x_{max} - x_{min})} + y_{min}, \quad (2.1)$$

де in_{prep} – нормалізований вхідний вектор, y_{max} та y_{min} – відповідно максимальне та мінімальне значення нейронів вхідного прошарку, in – вхідний вектор, x_{max} та x_{min} – відповідно максимальне та мінімальне значення вхідного вектора. Операція ділення проводиться поелементно.

На наступному етапі обчислюються значення нейронів у прихованих прошарках. Стан нейронів визначається за допомогою операції перемноження матриці синаптичних ваг та вектора, що містить значення нейронів попереднього прошарку, і пропущення отриманих значень через функцію активації. В розробленій системі використовується активаційна функція у вигляді гіперболічного тангенса. Дана функція є найбільш оптимальною, оскільки вона центрована відносно нуля та диференційована на всьому проміжку існування [117]. Для першого прихованого прошарку описані перетворення можна подати у вигляді:

$$y_1 = \tanh(IW \times in_{prep} + b_1), \quad (2.2)$$

де y_1 – вектор значень нейронів першого прихованого прошарку, IW – матриця синаптичних ваг між вхідним та першим прихованим прошарками, b_1 – вектор зміщень нейронів першого прихованого прошарку.

Для другого прихованого прошарку обчислення значень нейронів матимуть вигляд:

$$y_2 = \tanh(LW \times y_1 + b_2), \quad (2.3)$$

де y_2 – вектор значень нейронів другого прихованого прошарку, LW – матриця синаптичних ваг між першим та другим прихованими прошарками, b_2 – вектор зміщень нейронів першого прихованого прошарку. У разі наявності більшої кількості прихованих прошарків, обчислення значень нейронів у них відбувається за аналогічною до (2.3) формулою.

Значення нейронів вихідного прошарку, які є відповіддю мережі, обчислюються аналогічно:

$$y_{out} = \tanh(OW \times y_2 + b_3), \quad (2.4)$$

де y_{out} – вектор значень нейронів вихідного прошарку, OW – матриця синаптичних ваг між другим прихованим та вихідним прошарками, b_3 – вектор зміщень нейронів вихідного прошарку. В деяких випадках доцільно застосовувати лінійну функцію активації вихідних нейронів, тоді з формули (2.4) вилучається активаційна функція \tanh [118].

Останнім етапом роботи мережі є зворотне масштабування отриманих даних, яке необхідне для узгодження значень вихідних нейронів з діапазоном вхідних даних. Таке масштабування проводиться за формулою:

$$res = \frac{(y_3 - y_{out\ min}) * (x_{\max} - x_{out\ min})}{(y_{out\ max} - y_{out\ min})} + x_{out\ min}, \quad (2.5)$$

де res – вихідний вектор, $y_{out\ min}$ та $y_{out\ max}$ – відповідно мінімальне та максимальне значення вихідного вектора, $x_{out\ min}$ та $x_{out\ max}$ – відповідно мінімальне та максимальне значення вихідних нейронів, $*$ – операція поелементного множення.

Далі виконується фільтрація виходу мережі для отримання кодів класу у бінарному форматі, оскільки мережа повертає значення в діапазоні $[-1...1]$. Зазвичай, в рамках фільтрації всі значення нейронів, що перевищують 0,8, приймаються за одиницю, всі інші значення вважаються нулем:

$$res_{fi} = \begin{cases} 1, & res_i \geq 0,8, \\ 0, & res_i \leq 0,8. \end{cases} \quad (2.6)$$

де res_{fi} – фільтровані вихідні значення. В результаті отримується вектор бінарних значень $Y[m] = res$, що містить код номеру класу. Кількість елементів m вихідного вектора дорівнює кількості вихідних нейронів. Значення «1» прийме елемент вихідного вектора (нейрон), номер якого відповідає номеру визначеного класу, всі інші елементи матимуть значення «0».

Після фільтрації здійснюється переведення отриманого бінарного коду класу в десятковий номер класу N_{cl} за простим алгоритмом:

$$N_{cl} = \begin{cases} 1, & Y[1]=1, \\ 2, & Y[2]=1, \\ \vdots & \\ m, & Y[m]=1. \end{cases} \quad (2.7)$$

Визначення десяткового номера класу є фінальною операцією однієї ітерації, після чого на вхід мережі подається наступний вектор та всі дії повторюються. Цикл роботи НМ завершується після обробки останнього температурного профіля.

Блок-схема описаного алгоритму роботи нейромережевого модуля виявлення та класифікації дефектів наведена на рис. 2.5. На блок-схемі N_g – загальна кількість вхідних температурних профілів (пікселів термограми).

Отриманий вектор відповідей мережі, який містить номери класів для всіх точок (пікселів) термограми, передається в наступні блоки системи для побудови карти класів дефектів та бінарної карти дефектів. Водночас, температурні профілі дефектних ділянок ОК передаються до нейромережевих модулів визначення глибини залягання та розкриття дефектів. Сигналом старту для модуля визначення глибини є завершення роботи модуля класифікації. Старт модуля визначення розкриття відбувається по завершенню роботи модуля визначення глибини.

Алгоритм роботи модулів визначення глибини та розкриття дефектів є аналогічним до розглянутого вище. Основною відмінністю від алгоритму, показаного на рис. 2.5 є те, що в даному випадку вирішується задача прогнозування (регресії), а не класифікації. Тому фільтрація значень вихідних нейронів не виконується, так як і визначення номеру класу. У вихідному прошарку міститься лише один нейрон, значення якого є визначеною глибиною залягання або розкриттям дефектів (для відповідних модулів).

Структура обох нейромережевих модулів дефектометрії є однаковою, вони відрізняються лише вимірюваним параметром. Загальна блок-діаграма типового нейромережевого модуля показана на рис. 2.6.

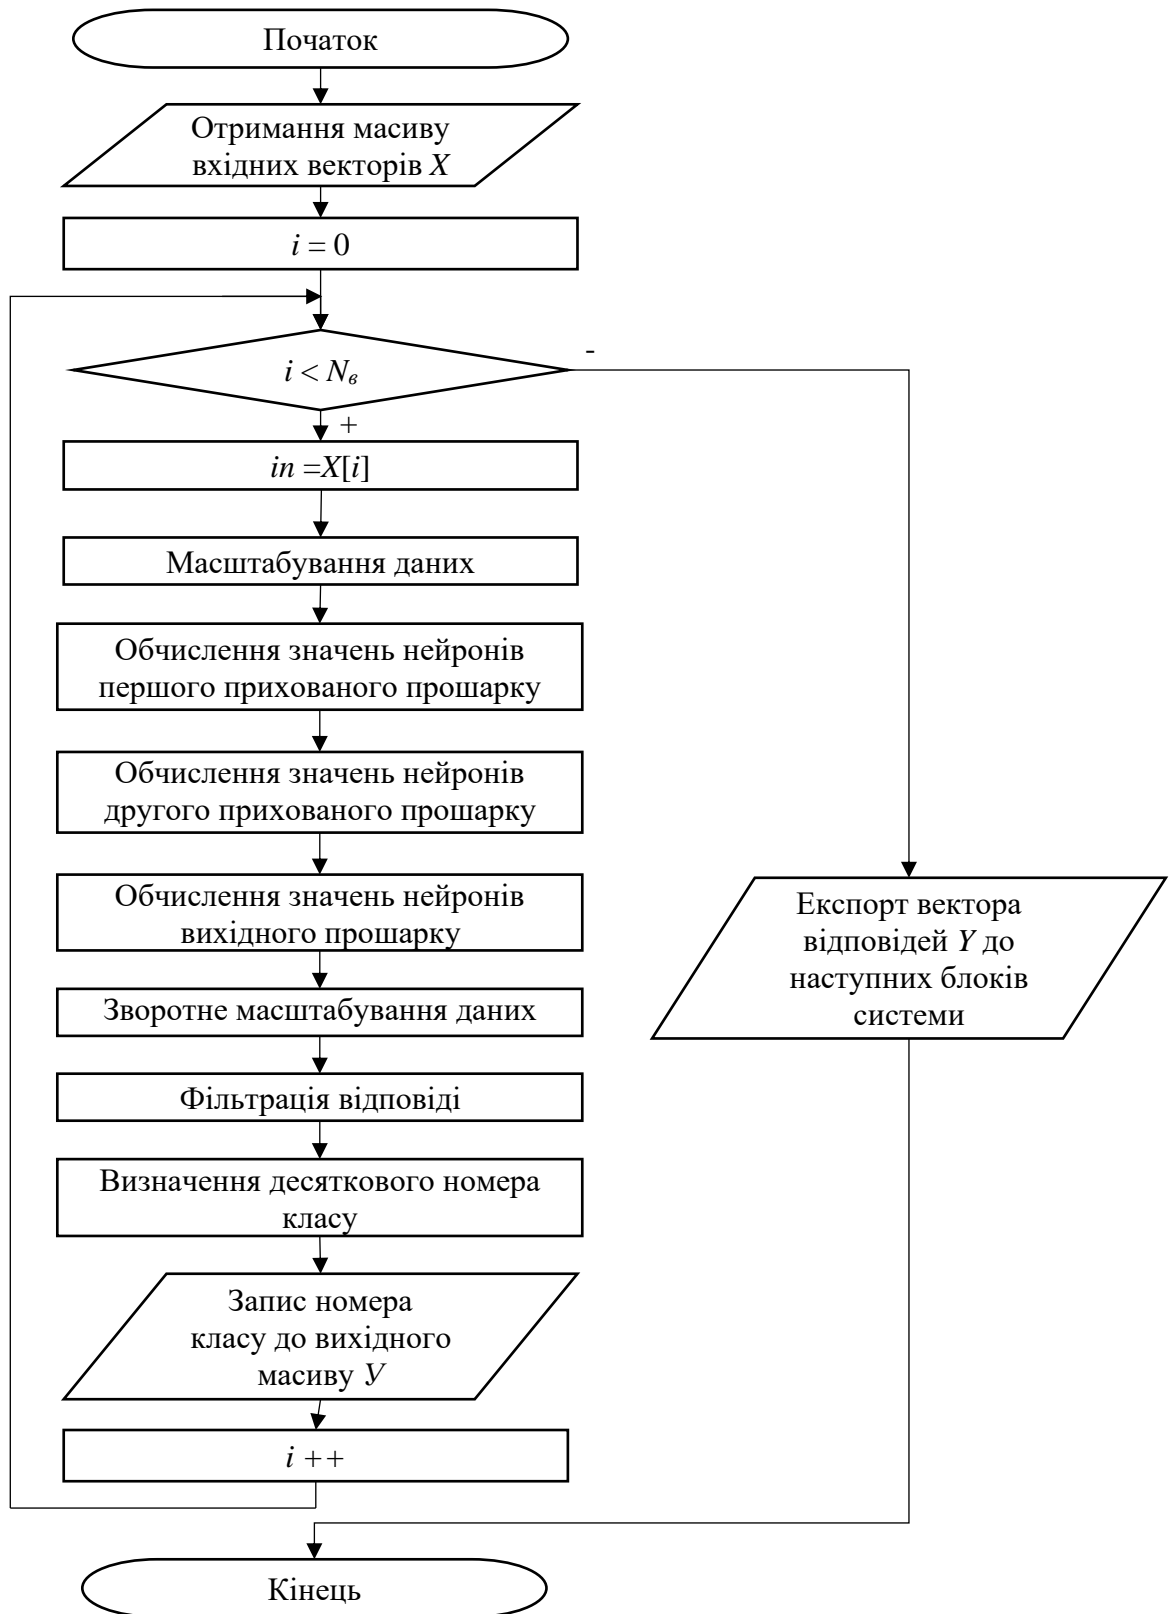


Рис. 2.5. Алгоритм роботи неймережевого модуля класифікації дефектів

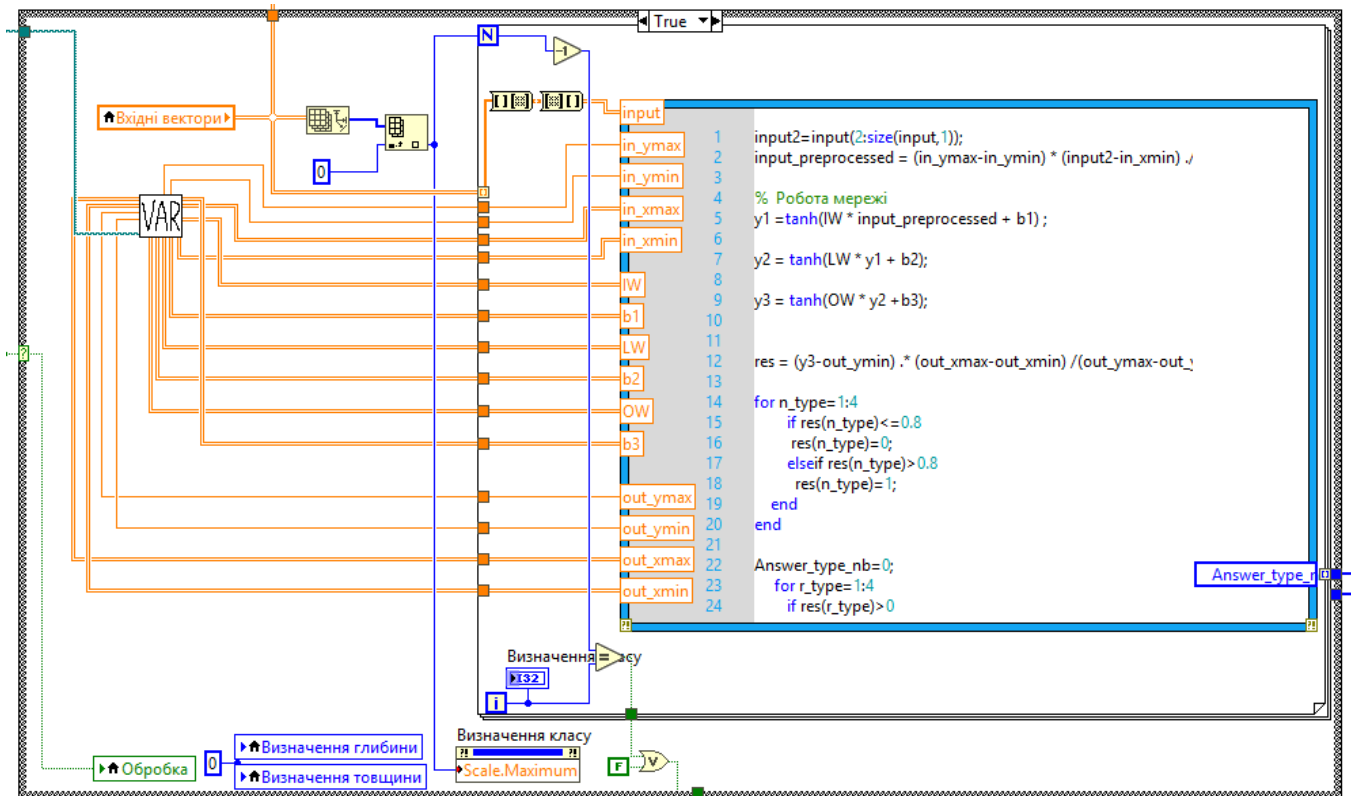


Рис. 2.6. Блок-діаграма типового нейромережевого модуля

2.4.3. Розробка блок-діаграм для реалізації пост-обробки відповідей нейромережевих модулів

Після завершення опрацювання нейронною мережею всіх вхідних векторів, на виході нейромережевого модуля формується вектор-рядок Y , що містить відповіді мережі на кожний вхідний зразок. Довжина даного вектора на виході модуля класифікації відповідає кількості пікселів у початковій термограмі (кількості температурних профілів), на виході модулів визначення глибини залягання та розкриття – кількості температурних профілів дефектних ділянок. Після закінчення роботи кожного нейромережевого модуля, отриманий вектор відповідей передається до відповідних блоків пост-обробки. Пост-обробка необхідна для зручного представлення користувачеві опрацьованих даних. Під час пост-обробки здійснюється побудова графічних карт дефектів, теплових томограм, фільтрація отриманих зображень з метою покращення результатів.

Розглянемо алгоритм пост-обробки відповіді нейромережевого модуля виявлення та класифікації дефектів. Отриманий на виході модуля вектор містить

номери класів для кожної точки (пікселя) термограми. З метою наочного подання результатів в системі аналізу даних теплового контролю із використанням удосконаленого методу визначення характеристик дефектів передбачена побудова графічних карт дефектів. Кожен дефект на такій карті подається у вигляді відповідної зони на термограмі. Кольори зон подані у 8-бітній шкалі градацій сірого. Дефекти різних типів будуть мати різну інтенсивність (яскравість). Бездефектним областям термограми відповідає чорний колір, що в цифровому форматі обраної шкали кольорів має інтенсивність 0. Ділянки, що відповідають дефектним областям, мають діапазон кольорів з інтенсивністю від 40 (темно-сірий) до 255 (білий). Для визначення кольору, що відповідає конкретному класу дефектів, використовується лінійна інтерполяція значень вектора відповідей Y за діапазоном можливих інтенсивностей (від 0 до 255). Інтерполяція в середовищі LabVIEW реалізується за допомогою віртуального підприладу *Interpolate 1D.vi*. В результаті даної операції вектор номерів класів перетворюється у вектор значень інтенсивностей сірого, що відповідають кожному номеру класу.

Вектор значень колірних інтенсивностей в точках термограми за допомогою функції *Reshape Array* трансформується в матрицю (двовимірний масив), розміри якої відповідають розмірам початкових термограм. Для переведення отриманого масиву інтенсивностей в формат зображення використовується функція *IMAQ Array to Image* набору інструментів NI Vision. З метою усунення артефактів, які виникають в результаті недосконалості програмних алгоритмів інтерполяції, до отриманого зображення застосовується медіанний фільтр. Оброблена карта класів (типів) дефектів виводиться на графічний індикатор на передній панелі ВП.

Для отримання бінарної карти дефектів до карти класів дефектів застосовується операція бінаризації. Зображення на бінарній карті складається лише з двох кольорів. Всі бездефектні області отримують значення чорного кольору, дефектні ділянки зображуються білим або червоним кольором в залежності від версії програмного забезпечення. В LabVIEW бінаризація зображення здійснюється за допомогою функції *IMAQ Threshold.vi*.

Після отримання карти класів дефектів та бінарної карти формується вектор, що містить номери температурних профілів, які відповідають дефектним ділянкам ОК. В наступних модулях даний вектор використовується для формування масиву вхідних векторів для НМ визначення глибини залягання та розкритву дефектів.

Блок-діаграма для реалізації описаних операцій показана на рис. 2.7.

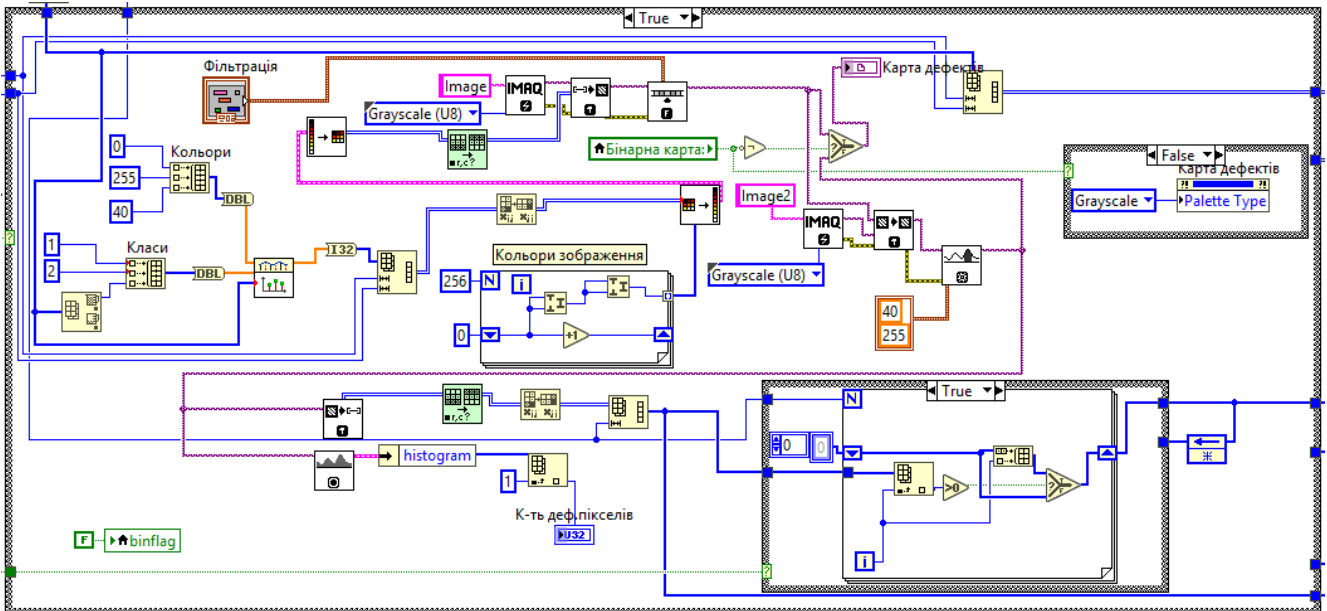


Рис. 2.7. Блок-діаграма алгоритму пост-обробки відповіді модуля класифікації

Спрощену блок-схему алгоритму роботи блоку пост-обробки відповіді нейромережевого модуля класифікації дефектів наведено на рис. 2.8. Після виконання зазначених операцій система формує сигнал старту роботи модуля визначення глибини залягання дефектів.

На виході нейромережевого модуля визначення глибини залягання дефектів формується вектор-рядок, який містить числові значення глибин залягання для кожної дефектної точки термограми. На першому етапі пост-обробки здійснюється розміщення значень глибин залягання для кожного пікселя на відповідних позиціях. Для цього використовується бінарна карта дефектів. За координатами кожного дефектного пікселя на бінарній карті відбувається підстановка на його місце відповідного елементу вихідного вектора нейромережевого модуля.

Отримана карта глибин залягання дефектів аналогічно до алгоритму попереднього блоку трансформується в формат зображення та фільтрується.

Отримане зображення використовується для побудови тривимірного графіка поверхні, що відображає розподіл глибин залягання дефектів. Блок-діаграма пост-обробки відповіді нейромережевого модуля визначення глибини зображена на рис. 2.9. Після завершення роботи даного блоку пост-обробки, формується сигнал для старту роботи нейромережевого модуля визначення розкриття дефектів.

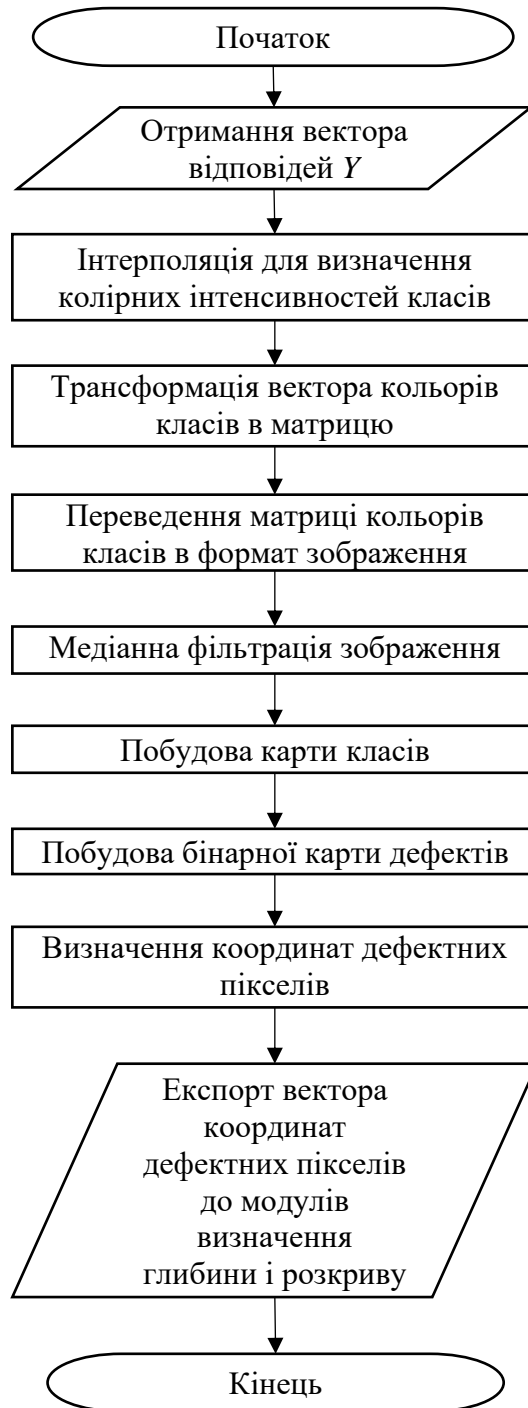


Рис. 2.8. Блок-схема алгоритму пост-обробки відповіді нейромережевого модуля виявлення та класифікації дефектів

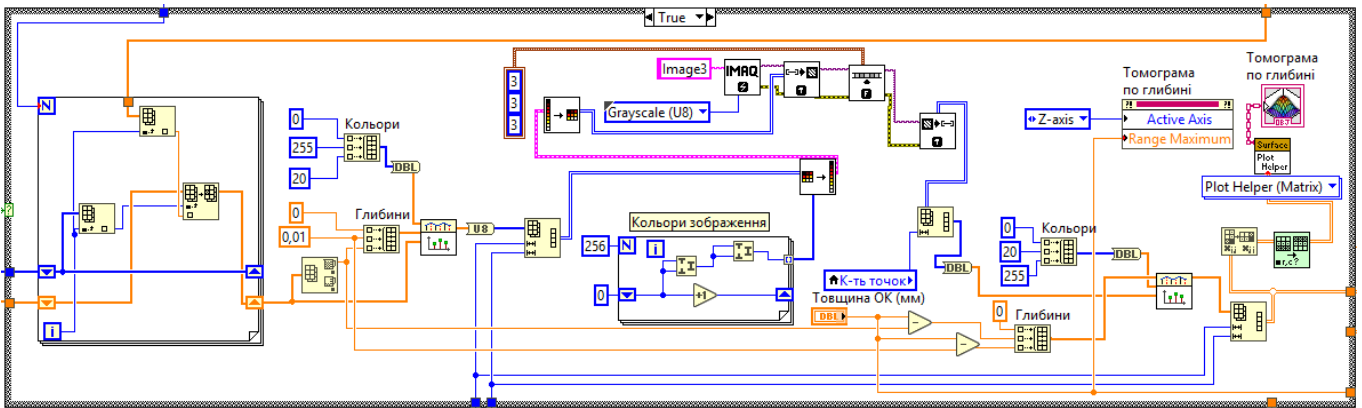


Рис. 2.9. Блок-діаграма пост-обробки відповіді модуля визначення глибини дефектів

Робота блоку пост-обробки модуля визначення розкриття дефектів відбувається аналогічно. Відмінністю є процедура побудови тривимірної томограми ОК, яка є зображенням його внутрішньої структури. Особливості програмного середовища LabVIEW на даному етапі не дозволяють побудувати повноцінну тривимірну томограму, використовуючи наявний формат даних. Тому в розробленій системі тривимірна томограма складається з двох графіків поверхні. Першим з них є раніше побудована томограма за глибиною залягання дефектів, яка відображається напівпрозорою. Другим графіком є аналогічна томограма, піксельні значення якої отримані у вигляді різниці глибини залягання та розкриття дефектів в кожній точці. В результаті поєднання двох графіків отримується комбіноване тривимірне зображення внутрішньої структури ОК, дефекти на якій показані у вигляді напівпрозорих вершин стовпчиків томограми. Недоліком є неможливість відображення дефектів, які розташовані один під одним [119].

Спрощена узагальнена блок-схема алгоритмів пост-обробки модулів визначення глибини залягання та розкриття дефектів наведена на рис. 2.10. Частина блок-діаграми, що реалізує пост-обробку відповіді нейромережевого модуля визначення розкриття дефектів, показана на рис. 2.11. Завершення роботи останнього блоку пост-обробки формує сигнал переведення системи в режим аналізу отриманих даних. Робота нейромережевих модулів зупиняється до моменту надходження нових вхідних даних або примусового перезапуску.

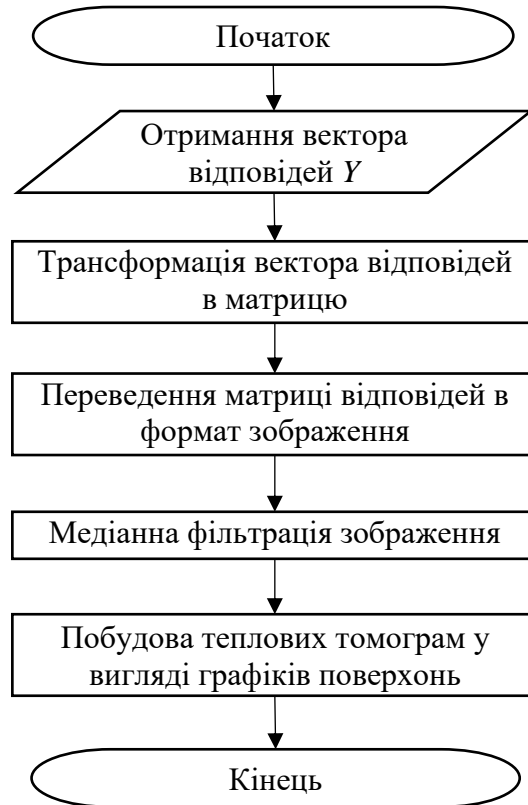


Рис. 2.10. Блок-схема алгоритмів пост-обробки відповідей модулів визначення глибини та розкриття дефектів

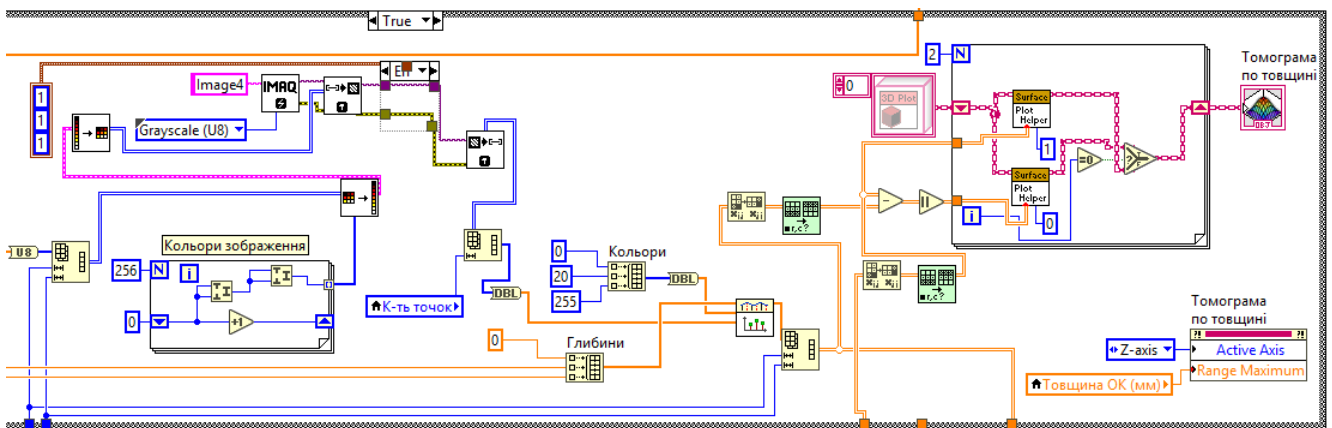


Рис. 2.11. Блок-діаграма пост-обробки відповіді модуля визначення розкриття дефектів

2.4.4. Розробка інтерфейсу користувача системи аналізу даних теплового контролю із використанням удосконаленого методу визначення характеристик дефектів

Взаємодія та керування автоматизованою системою аналізу даних теплового контролю із використанням удосконаленого методу визначення характеристик дефектів відбувається за допомогою інтерфейсу користувача на передній панелі ВП. Інтерфейс складається з двох вкладок, які призначені для попередніх налаштувань та обробки отриманих даних. Після запуску ВП користувач обирає режим роботи: старт нового вимірювання або аналіз існуючих даних.

Передня панель ВП містить блоки імпорту необхідних файлів, налаштувань системи та метрологічні характеристики нейромережових модулів. На початку роботи користувач повинен вказати шлях до файлів, які містять навчені моделі нейронних мереж для кожного нейромережевого модуля. Також необхідно вказати шлях до файлу, який містить записану послідовність термограм. Якщо тепловізійне обладнання дозволяє потокову передачу даних в режимі реального часу, існує можливість модернізації системи для отримання записаної послідовності термограм безпосередньо з тепловізора під час вимірювань. В існуючій версії системи послідовність термограм має бути представлена у вигляді двовимірного масиву, рядки якого є трансформованими у вигляд вектора термограмами. Масив вхідних даних, а також навчені моделі НМ мають бути записаними до текстових файлів.

Після налаштувань шляхів до необхідних файлів, користувач має задати розміри термограм у послідовності та вказати максимальну товщину ОК для коректної побудови всіх зображень та термограм.

В другій половині вкладки налаштувань міститься інформація щодо характеристик системи. Значення всіх похибок можуть бути отримані як на валідаційній множині під час навчання відповідної нейромережі, так і за результатами тестування мережі на експериментальних стандартних зразках. Для

модуля виявлення та класифікації дефектів вказана помилка класифікації δ_{cl} , що визначається за даними бінарної карти як:

$$\delta_{cl} = \left(1 - \frac{N_{cd}}{N_d}\right) \times 100\%, \quad (2.8)$$

де N_{cd} – кількість коректно класифікованих дефектних пікселів, N_d – загальна кількість дефектних пікселів [120].

Під час визначення помилки класифікації можуть також бути враховані пікселі, що хибно визначені як дефектні. Тоді формула (2.8) отримає вигляд:

$$\delta_{cl} = \left(1 - \frac{|N_{cd} - N_{fd}|}{N_d}\right) \times 100\%, \quad (2.9)$$

де N_{fd} – кількість хибних дефектних пікселів.

Якщо оцінка характеристик нейромережових модулів системи проводилось на експериментальних тестових зразках, додатково можуть бути обчислені значення відносної похибки визначення розмірів дефектів та критерію Танімото. Для модулів визначення глибини залягання та розкриву дефектів наводяться середні значення абсолютних похибок, середньоквадратичні абсолютні похибки та граничні відносні похибки (для довірчого інтервалу 3σ).

Після виконання усіх необхідних налаштувань, користувач переходить на вкладку «Обробка», яка є головним робочим інтерфейсом (рис. 2.12). Головне вікно містить кнопки керування системою та нейромережевими модулями, індикатори стану роботи системи, блок з інформацією про визначені параметри дефектів, блок вибору масштабу та область графічної інформації.

Блок керування системою містить три основних кнопки. Кнопка «Новий зразок» призначена для запуску імпорту вхідної послідовності термограм та старту її обробки нейромережевими модулями. Після завершення обробки, система автоматично переходить в режим аналізу даних, який дозволяє скористатись відповідними інструментами дефектометрії. Кнопка «Старт НМ» запускає роботу нейромережових модулів без повторного імпорту вхідного масиву даних. Таким

чином, відбувається обробка результатів контролю одного і того ж ОК, що дозволяє протестувати роботу різних НМ та визначити вплив зміни параметрів системи без необхідності перезавантаження вхідних даних. Кнопка «Зупинити» призначена для зупинки роботи ВП в будь-який момент часу. Поточний режим роботи системи можна визначити за допомогою відповідних індикаторів, які розташовані під блоком кнопок керування. Увімкнений стан світлодіоду «Обробка» означає, що в даний момент здійснюється обробка даних нейромережевими модулями.

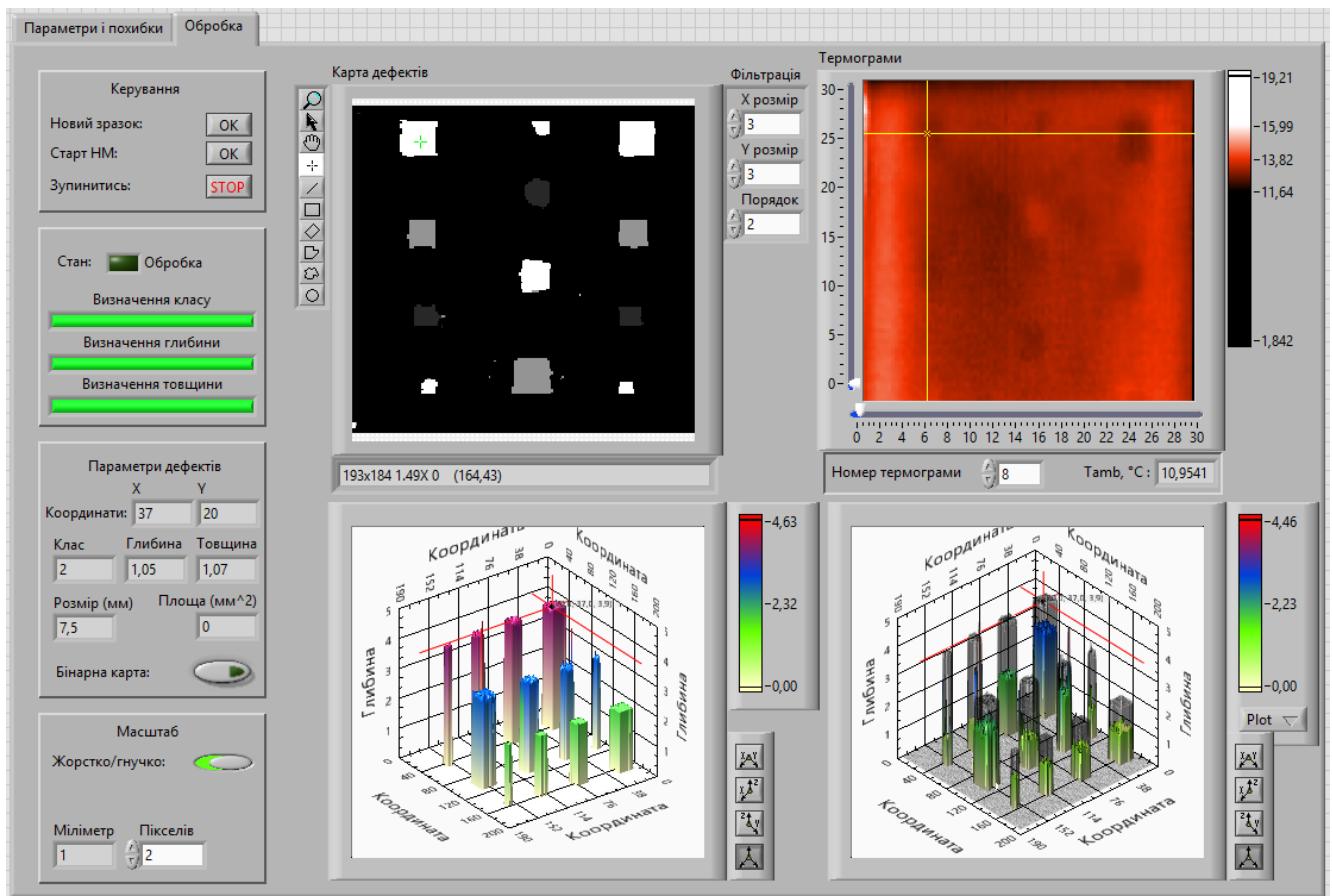


Рис. 2.12. Передня панель головної робочої області системи

У блоці параметрів дефектів міститься вся інформація щодо координат, класів, глибин залягання та розкриттів визначених дефектів. Вимірювання параметрів здійснюється за допомогою панелі інструментів, яка знаходиться на лівій грані графічного індикатора карти дефектів. Із використанням даних інструментів існує можливість масштабування карти, проведення точкових вимірювань параметрів дефектів (визначення типу, глибини залягання та розкриття в даній точці), вимірювання лінійних розмірів та площі дефектів. Перемикач

«Бінарна карта» визначає режим відображення карти дефектів: карта типів дефектів або власне бінарна карта.

Під блоком параметрів дефектів розташовані регулятори масштабу, призначені для налаштування способу вимірювання розмірів на карті дефектів. Користувач може обрати два режими:

- Жорстко: масштаб прив'язаний до кількості пікселів;
- Гнучко: масштаб задається за допомогою процедури калібрування.

Область візуальної інформації складається з чотирьох графічних індикаторів. На першому з них виводиться отримана за результатами роботи нейромережових модулів карта дефектів. Використовуючи карту та описані вище інструменти, здійснюється визначення параметрів дефектів. На правій грані карти дефектів розташовані налаштування медіанного фільтру. На другому графічному індикаторі зображується термограма із початкової послідовності. Номер бажаної для відображення термограми вказується у відповідному регуляторі. Також можна застосувати курсор для вимірювання надлишкових температур. На третьому та четвертому графічних індикаторах зображується теплова томограма за глибиною залягання дефектів та томограма внутрішньої структури ОК відповідно. За допомогою панелі інструментів можна керувати режимом відображення графіків. Для оцінки параметрів дефектів на томограмах використовується курсор.

Отже, можна сформулювати загальний алгоритм роботи розробленої системи аналізу результатів активного теплового контролю із використанням удосконаленого методу визначення характеристик дефектів виробів із багатошарових матеріалів (рис. 2.13). На першому етапі виконується запуск ВП та вводяться первинні налаштування нейромережових модулів та підсистеми дефектометрії. Далі на головній робочій вкладці за натиском кнопки «Новий зразок» автоматизована система розпочинає імпорт записаної послідовності термограм. Після завантаження вхідних даних розпочинається робота нейромережового модуля виявлення та класифікації дефектів. У результаті роботи модуля на його виході формується вектор, який містить номери класів дефектів для кожної точки термограми.

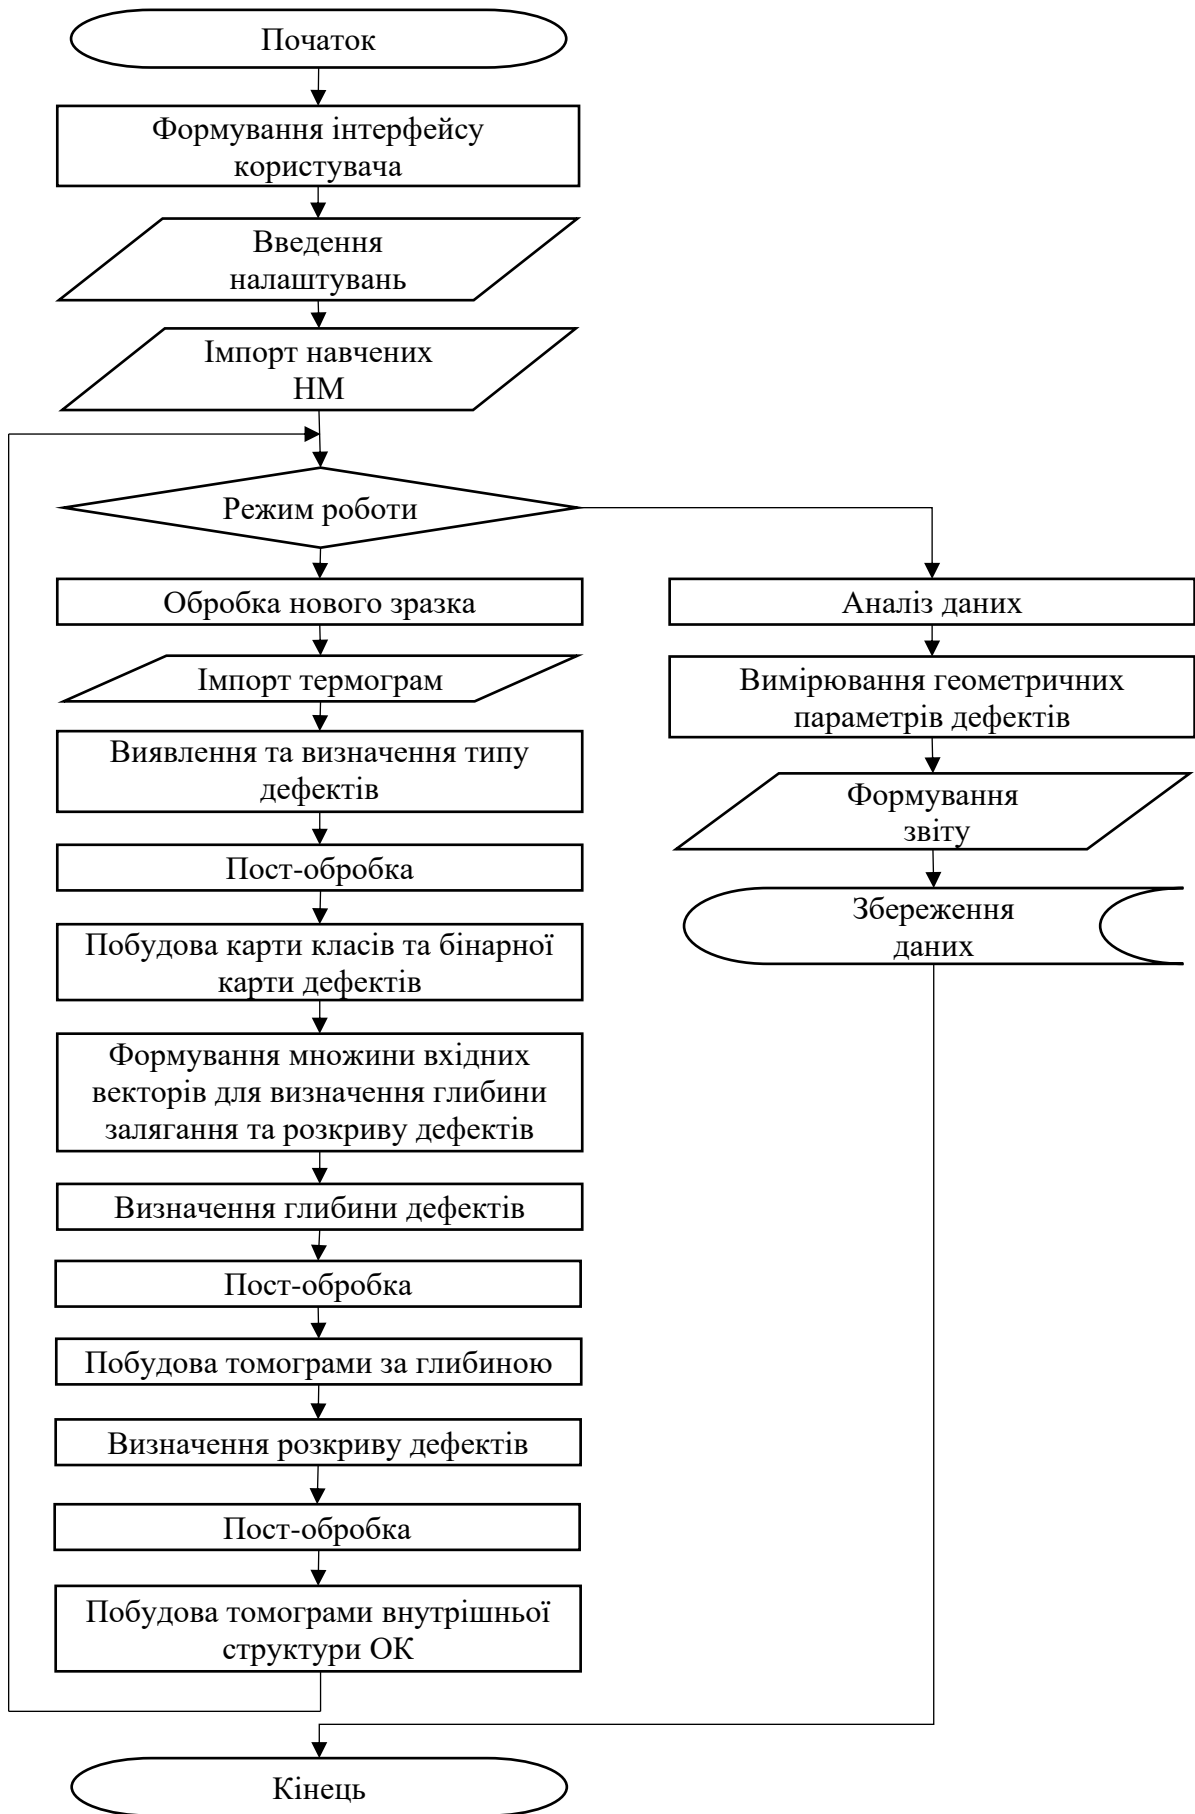


Рис. 2.13. Блок-схема алгоритму роботи розробленого віртуального приладу

Після цього здійснюється пост-обробка отриманих даних та побудова карти класів та бінарної карти дефектів. Водночас, формується множина температурних профілів в пікселях дефектних ділянок. Сигнали із дефектних точок передаються до модуля визначення глибини залягання дефектів. Результатом роботи модуля є вектор, який містить значення глибин залягання для точок і дефектних областей. На основі отриманих даних будується теплова томограма ОК за глибинами залягання дефектів. Множина температурних профілів в дефектних точках передається до модуля визначення розкриву дефектів, за результатами роботи якого будується томограма внутрішньої структури ОК. Подальший аналіз даних та вимірювання поперечних розмірів дефектів здійснюється оператором, який складає звіт за результатами контролю.

Висновки до розділу 2

1. На основі аналізу існуючих схем активного теплового контролю синтезовано схему реалізації автоматизованої системи аналізу даних теплового контролю із використанням удосконаленого методу визначення характеристик дефектів. Запропоновано автоматизоване проведення системою цифрової обробки даних в трьох нейромережевих модулях. Модульна структура полегшує побудову та модифікацію системи, підвищує загальну ефективність її роботи завдяки оптимізації налаштувань модулів для вирішення конкретних задач.

2. Проаналізовано типи нейронних мереж, що можуть бути застосовані для обробки даних теплового контролю. Встановлено переваги та недоліки різних типів нейромереж. Запропоновано та обґрунтовано найбільш оптимальний тип нейромережі для використання в складі аналізу даних теплового контролю із використанням удосконаленого методу визначення характеристик дефектів – багат шарову нейронну мережу прямого розповсюдження зі зворотним поширенням помилки. Дана мережа застосовується для ефективного вирішення як задач класифікації, так і прогнозування, що дозволяє використовувати її одразу в усіх трьох нейромережевих модулях системи. Уніфікація типу нейромережі сприяє спрощенню структури модулів та системи загалом.

3. Для обраного типу нейронної мережі обґрунтовано та розроблено алгоритми формування множин навчальних векторів. Розглянуто особливості формування навчальної вибірки для задач класифікації дефектів та визначення їх параметрів в активному тепловому контролі. На основі аналізу літературних джерел запропоновано використання алгоритмів формування навчальної множини, яка містить три підмножини: навчальну, тестову і валідаційну.

4. В середовищі NI LabVIEW розроблено віртуальні прилади, що реалізують алгоритм роботи системи аналізу даних теплового контролю із використанням удосконаленого методу визначення характеристик дефектів. Розроблено блок-діаграми трьох нейромережевих модулів та алгоритми їх взаємодії і пост-обробки даних, зокрема, побудови карт дефектів і теплових томограм. Вперше розроблено єдиний інтерфейс користувача, що дозволяє проводити комплексний аналіз послідовностей термограм. Автоматизовано процес виявлення та класифікації дефектів, визначення їх глибини залягання та розкриття.

РОЗДІЛ 3

ОБРОБКА РЕЗУЛЬТАТІВ КОМП'ЮТЕРНОГО МОДЕЛЮВАННЯ ПРОЦЕСУ АКТИВНОГО ТЕПЛОВОГО КОНТРОЛЮ ІЗ ВИКОРИСТАННЯМ УДОСКОНАЛЕНОГО МЕТОДУ ВИЗНАЧЕННЯ ХАРАКТЕРИСТИК ДЕФЕКТІВ

З метою тестування та оцінки ефективності розробленої автоматизованої системи активного ТНК із використанням удосконаленого методу визначення характеристик дефектів проводиться комп'ютерне моделювання процесу активного теплового контролю та дефектометрії різних об'єктів. Комп'ютерне моделювання дозволяє отримати послідовності термограм для різних ОК, різних умов та схем контролю. Дані комп'ютерного моделювання використовуються для навчання нейромережових модулів та тестування роботи системи, оцінки її метрологічних характеристик та вибору оптимальних налаштувань. Перевагою використання комп'ютерного моделювання є можливість створення широкої бази множин навчальних векторів для нейронних мереж.

3.1. Програмне забезпечення для створення комп'ютерної моделі процесу активного теплового контролю

Важливим завданням є вибір програмного середовища для проведення комп'ютерного моделювання, яке забезпечує високу достовірність та адекватність створених моделей, а також є зручним у користуванні. На сьогоднішній день одним із найбільш оптимальних рішень в даній області є COMSOL Multiphysics – програмне забезпечення для аналізу, розв'язку та імітації різноманітних фізичних явищ та інженерних задач [121]. Основною перевагою даного пакету є можливість використання мультифізики – поєднання в одній моделі фізичних явищ різної природи. У програмі доступні вбудовані модулі, які містять всі інструменти для комп'ютерного моделювання різних фізичних процесів. Всі модулі розділені згідно

з процесами, з якими вони працюють. Для вирішення поставлених задач використовується модуль теплопередачі в твердих тілах (Heat transfer in solids).

Для вирішення задач моделювання фізичних процесів в COMSOL Multiphysics використовується метод кінцевих елементів (finite element method) та його модифікації. FEM – числова техніка знаходження розв'язків інтегральних та диференціальних рівнянь у частинних похідних (ДРЧП). Процес розв'язання побудований або на повному усуненні диференціального рівняння для стаціонарних задач, або на розкладі ДРЧП в апроксимуючу систему звичайних диференціальних рівнянь, які потім розв'язуються використанням стандартних методик. Під час розв'язання часткових диференціальних рівнянь головною метою є створення рівності, що апроксимує досліджувану рівність, і є числово стабільною, тобто помилки у вхідних даних і проміжних обчисленнях не акумулюються і не спричиняють беззмислових результатів. FEM задовольняє даній умові [122].

Для зручності користування під час моделювання використовується вбудований помічник, який дозволяє програмі автоматично вибрати оптимальні налаштування. В результаті розрахунку моделі отримується послідовність із заданої кількості термограм. Точність розрахунків визначається автоматично або задається користувачем. Для моделювання активного теплового контролю рекомендується обирати високу (extra fine) точність. Отримана послідовність термограм експортується до текстових файлів для подальшої обробки.

3.2. Комп'ютерне моделювання процесу активного теплового контролю зразка з багат шарового композиційного матеріалу

Як було розглянуто раніше, багат шарові композиційні матеріали мають ряд властивостей та особливостей, які ускладнюють визначення параметрів їх дефектів традиційними методами. З метою оцінки ефективності роботи розробленої автоматизованої системи визначення характеристик дефектів в задачах контролю багат шарових композитів, а також для порівняння її ефективності з існуючими традиційними методами обробки температурних профілів, проведено комп'ютерне моделювання активного ТНК відповідного зразка. На відміну від однорідних

металів, КМ з меншою інтенсивністю піддаються впливу теплової дифузії, що дозволяє більш точно оцінити форму їх внутрішніх дефектів. В той же час, такі матеріали зазвичай мають меншу теплопровідність, що призводить до необхідності збільшувати потужність джерела нагріву або проводити нагрів протягом більшого часу. В останньому випадку, падає ефективність методів Фур'є- та вейвлет-аналізу, а також роздільна здатність динамічної теплової томографії [123].

3.2.1. Створення комп'ютерної моделі зразка та опис експерименту

Для проведення моделювання розроблено геометричну модель ОК у вигляді пластини з п'яти шарів вуглепластику. Кожний шар має товщину 1 мм, загальна товщина пластини становить 5 мм. Пластина квадратної форми зі стороною 100 мм. Всередині пластини на глибині залягання 1, 2 та 3 мм розміщені моделі штучних дефектів квадратної форми. Дані дефекти мають поперечні розміри 10, 8, 6 та 4 мм і розкрив 1, 2 та 3 мм. Схема розміщення дефектів показана на рис. 3.1. Всього закладено моделі трьох різних типів дефектів – повітряні порожнини (позначені на рис. 3.1 білим кольором), алюмінієві сторонні включення (синій колір на схемі) та паперові включення (червоний колір на схемі). Такі матеріали дефектів обрані з метою моделювання випадків, в яких теплопровідність дефекту має більше (алюміній), менше (повітря) або приблизно однакове (папір) значення порівняно з матеріалом ОК. Під час створення моделі всі зазначені матеріали були обрані зі стандартної вбудованої бібліотеки COMSOL Multiphysics.




Рис. 3.1. Схема комп'ютерної моделі зразка з багатошарового вуглепластику

Для моделювання обрано двосторонню схему контролю. До передньої поверхні ОК прикладено імпульсне джерело теплового потоку з густиною потужності $10 \text{ кВт} / \text{м}^2$. Тривалість імпульсу нагріву становила 1 с, тривалість стадії охолодження 14 с. Результатом моделювання стало отримання послідовності із 50 термограм, які відображають весь процес нагріву/охолодження. Термограми записувались зі сторони задньої поверхні ОК протягом всієї процедури нагріву/охолодження. В результаті записано послідовність із 50 термограм, кожна з яких має розмір 400×400 пікселів. Отриманий набір даних було експортовано до середовища MATLAB для здійснення подальшої обробки.

В результаті моделювання активного ТНК зразка з багат шарового КМ внаслідок залежності оптимального часу контролю від глибини залягання дефектів неможливо встановити одну оптимальну термограму. Тому оптимальний час контролю було обрано для всіх трьох можливих глибин залягання. Оптимальна термограма для виявлення дефектів на глибині 1 мм показана на рис. 3.2. Штучні дефекти, які мають більшу теплопровідність, ніж матеріал ОК, мають позитивне значення температурного сигналу ΔT . Дефекти з меншою теплопровідністю відносно ОК мають від'ємне значення температурного сигналу.




Рис. 3.2. Оптимальна термограма для виявлення дефектів на глибині 1 мм

За отриманими оптимальними термограмами для трьох глибин залягання дефектів побудовано бінарні карти (рис. 3.3). На відміну від металевого ОК, у зразку з композиційного матеріалу завдяки меншій теплопровідності форма

дефектів збережена більш достовірно. На карті візуально виявляються всі закладені штучні дефекти. Внаслідок бінаризації не втрачається інформація щодо кількості дефектів, їх форма та площа спотворюються в меншому ступені. Це дозволяє проводити вимірювання поперечних розмірів дефектів за їх відбитками на оптимальних термограмах. Кількісна оцінка точності визначення характеристик дефектів даним методом наводиться далі.

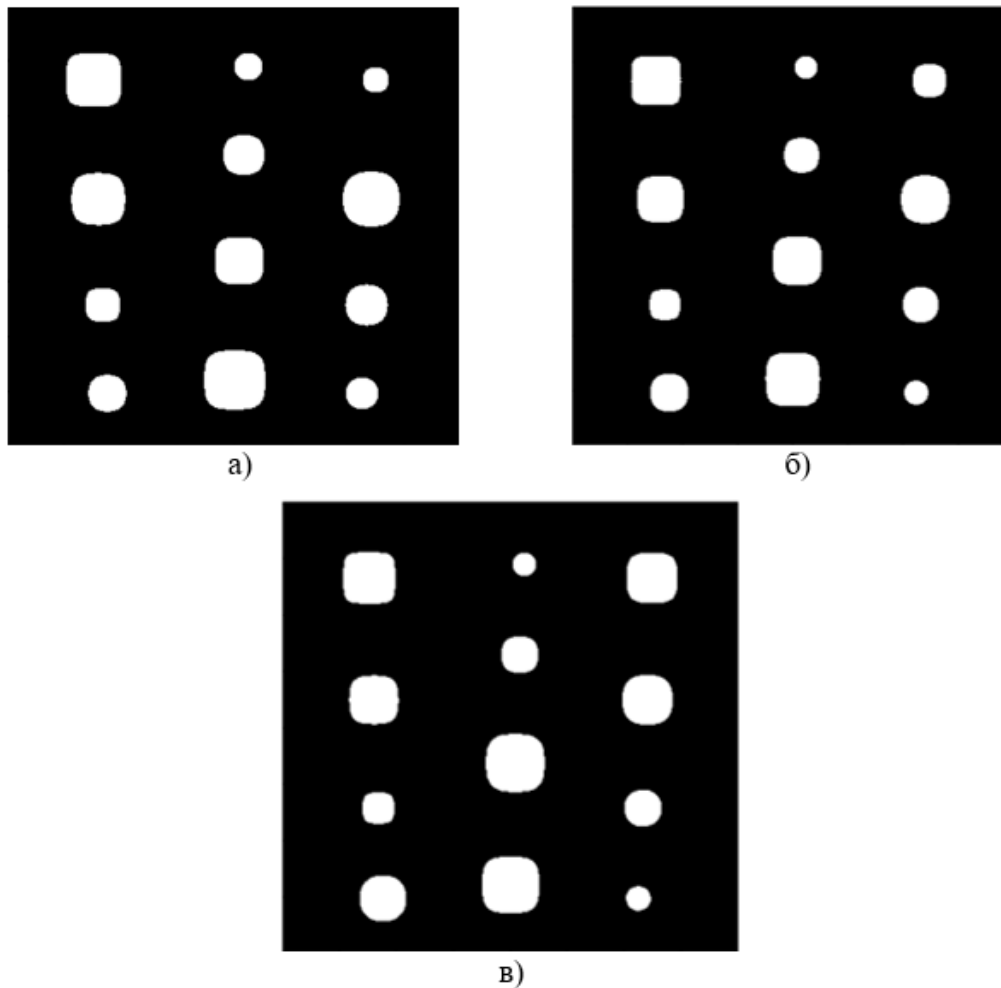


Рис. 3.3. Бінарні карти дефектів за оптимальними термограмами для глибини залягання: а) – 1 мм, б) – 2 мм, в) – 3 мм

На рис. 3.4 показані температурні профілі для бездефектної ділянки та різних типів дефектів. До розгляду обрані надлишкові температури. На даних графіках підтверджено залежність знаку і величини диференціального температурного сигналу від відношення теплопровідностей дефектів та ОК. Наведені дані можуть бути використані оператором або автоматизованою системою для класифікації дефектів за теплопровідністю. Однак, в реальних умовах характер даної залежності

може бути порушений внаслідок нерівномірного нагріву або впливу інших завад. Під час проведення моделювання на поверхні ОК не було закладено штучних джерел теплових потоків для імітації нерівномірності нагріву, оскільки проводився порівняльний аналіз ефективності різних методів обробки термограм для випадку ідеальних умов контролю.




Рис. 3.4. Температурні профілі для бездефектної ділянки ОК та дефектів різних типів

На рис. 3.5 показані приклади температурних сигналів від різних дефектів, що лежать на глибині залягання 2 мм та 3 мм. На рис. 3.5, а зображені температурні сигнали для повітряних порожнин стороною 6 мм. Оптимальний час контролю для даного випадку майже однаковий. Для дефектів у вигляді алюмінієвих включень більш суттєво виражена залежність часу оптимального спостереження τ_{opt} від глибини залягання.

Отримані в результаті моделювання температурні профілі свідчать про складність їх однозначної інтерпретації. Для дефектів у вигляді повітряних порожнин та алюмінієвих включень характер залежностей оптимального часу спостереження від глибини залягання відрізняється. Внаслідок цього неможливо встановити єдине правило щодо визначення глибини для дефектів різних типів, що значно ускладнює автоматизацію процесу теплової дефектометрії із використанням класичних методів обробки температурних профілів.




Рис. 3.5. Приклади температурних сигналів від дефектів на різних глибинах залягання: а) – повітряні порожнини, б) – алюмінієві включення

3.2.2. Обробка результатів моделювання традиційними методами

В результаті застосування перетворення Фур'є до початкової послідовності термограм отримано зображення Фур'є-образів на різних частотах. Ампліграма на першій частоті показана на рис. 3.6, а та є малоінформативною, оскільки подібна до оптимальних термограм. На рис. 3.6, б показана фазограма на 21-ій частоті. У порівнянні з оптимальними термограмами, можна відмітити більш чітке зображення форми дефектів та підвищення співвідношення сигнал/шум. Для дефекту у вигляді алюмінієвого включення розміром 4 мм на глибині залягання 1 мм на фазограмі з'являється кільцевий артефакт. Метод Фур'є аналізу не дозволяє провести класифікацію дефектів, визначити глибину їх залягання та розкрити.




Рис. 3.6. Результати Фур'є-аналізу промодельованої послідовності термограм: а) – ампліграма на другій частоті, б) – фазограма на 21-ій частоті

На базі отриманих результатів автоматично побудовано бінарну карту дефектів (рис. 3.7). Внаслідок операції бінаризації за пороговим рівнем форма та площа дефектів зазнали незначного викривлення. В цілому, на карті виявлено всі приховані дефекти, а за якістю вона є подібною до бінарних карт на базі оптимальних термограм. Під час побудови карти дефектів артефакт навколо дефекту розміром 4 мм злився з тепловим відбитком істинного дефекту, що погіршило якість визначення його форми. Це ставить під сумнів доцільність бінаризації в даному випадку, а отже і можливість автоматизації контролю даним методом. Кількісна оцінка результатів обробки промодельованої послідовності термограм багат шарового ОК наведена в таблиці 3.2.




Рис. 3.7. Бінарна карта за результатами Фур'є-аналізу

Отримані за результатами методу вейвлет-перетворення ампліграми показані на рис. 3.8. Найбільш інформативними виявились ампліграми на дев'ятій (рис. 3.8, а) та 15-ій (рис. 3.8, б) частотах. Водночас, вказані зображення є подібними до оптимальних термограм, аналогічно до методу Фур'є-аналізу. Оскільки розрахунок перетворення вейвлет зайняв 158 хвилин обчислювального часу, а отримані результати є подібними до Фур'є-аналізу, постає питання доцільності застосування вейвлетів у даній задачі.




Рис. 3.8. Результати вейвлет-аналізу промодельованої послідовності термограм: а) – ампліграма на 9-ій частоті, б) – ампліграма на 15-ій частоті

Фазограми вейвлет-образів (рис. 3.9) носять неоднозначний характер. Форма виявлених дефектів на фазограмах є більш чіткою. Водночас, з'являються сторонні артефакти, що унеможливають побудову бінарних карт за фазограмами та ускладнюють їх аналіз. Використання методу вейвлет-аналізу на даному етапі розвитку не дозволяє проводити автоматичну класифікацію дефектів, визначати їх глибину залягання та розкрити.

На рис. 3.10 показана бінарна карта, побудована на основі ампліграм вейвлет-перетворення. Бінарна карта за даним методом є подібною до карт, отриманих методом Фур'є-аналізу або на базі оптимальних термограм. Кількісна оцінка точності вимірювання характеристик дефектів за побудованою бінарною картою наводиться в таблиці 3.2.




Рис. 3.9. Фазограми вейвлет-образів промодельованої послідовності термограм: а) – на другій частоті, б) – на третій частоті




Рис. 3.10. Бінарна карта дефектів, побудована за результатами вейвлет-аналізу промодельованої послідовності термограм

В результаті обробки початкової послідовності термограм за методом аналізу головних компонент, найбільш інформативними є зображення на другій (рис. 3.11, а) та п'ятій (рис. 3.11, б) головних компонентах. Для деяких дефектів форма визначена більш коректно у порівнянні з оптимальними термограмами. В той же час, помітне погіршення точності визначення границь та розмірів дефектів.

На рис. 3.12 показана бінарна карта дефектів, побудована на базі отриманих за МАГК даних. Навколо повітряного дефекту розміром 6 мм на глибині залягання 1 мм міститься сторонній артефакт. Кількісна оцінка характеристик виявлених дефектів наводиться в таблиці 3.2.




Рис. 3.11. Обробка промодельованої послідовності термограм за МАГК: а) – друга головна компонента, б) – п'ята головна компонента

На сьогоднішній день невідомі алгоритми класифікації дефектів методом аналізу головних компонент. Так само не досліджені можливості визначення глибини залягання та розкриву даним методом. Зображення на різних головних компонентах несуть різну інформацію для кожного окремого ОК, що ускладнює можливість автоматизації обробки термограм. Для кожної процедури контролю необхідно проводити окремий аналіз отриманих результатів, оскільки вони є непередбачуваними [124].




Рис. 3.12. Бінарна карта дефектів за МАГК

За методом ДТТ побудовано максіграму (рис. 3.13, а) та таймограму (рис. 3.13, б) ОК. У порівнянні з оптимальними термограмами, форма та розміри теплових відбитків дефектів на максіграмі є близькими до істинних параметрів штучних дефектів. Водночас, на таймограмі спостерігаються крайові ефекти на

границях відбитків дефектів. На основі отриманих даних побудовано бінарну карту дефектів та теплову томограму ОК за глибинами залягання дефектів (рис. 3.14). Бінарна карта є подібною до отриманих за іншими методами обробки. Спостерігається викривлення форми дефектів та збільшення розмірів їх теплових відбитків, що призводить до зростання похибки визначення геометричних розмірів.




Рис. 3.13. Обробка промодельованої послідовності термограм методом ДТТ:

а) – максіграма, б) – таймограма

На тепловій томограмі глибини залягання дефектів визначені переважно хибно. Це можна пояснити неоднозначним характером температурних сигналів, описаним в попередньому пункті. Внаслідок наявності крайових ефектів на таймограмі, форма дефектів на тепловій томограмі також спотворена. Коректно відтворена глибина залягання для дефекту у вигляді алюмінієвого включення на глибині 1 мм та повітряної порожнини розміром 10 мм на глибині 2 мм. За допомогою відомих модифікацій методу ДТТ неможливо провести автоматичну класифікацію дефектів та оцінити їх розкрив. Кількісна оцінка точності визначення геометричних розмірів дефектів на базі бінарної карти, отриманої за методом ДТТ, наводиться в таблиці 3.2.

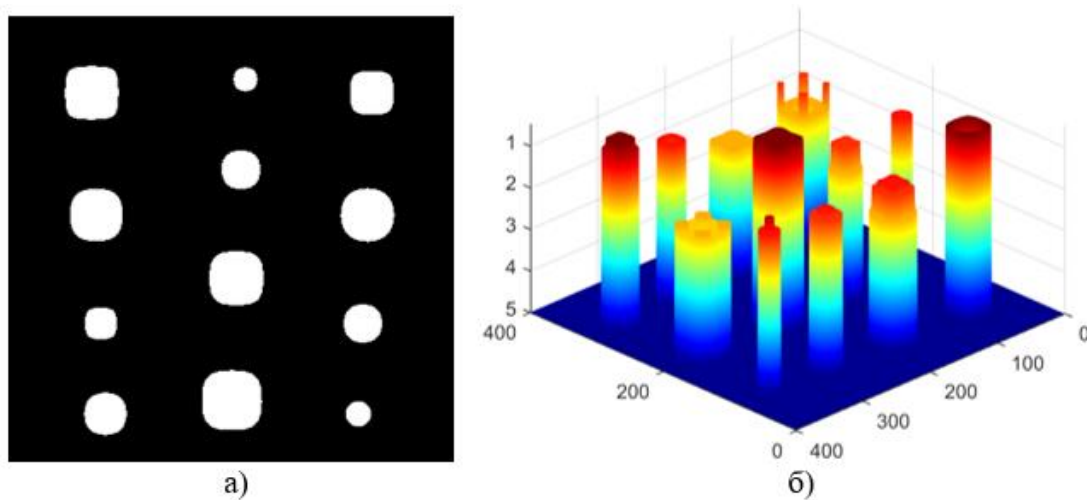


Рис. 3.14. Результати обробки отриманих максіграми та таймограми: а) – бінарна карта дефектів, б) – теплова томограма

3.2.3. Формування навчального набору даних для нейромережевих модулів

З метою формування набору навчальних векторів для нейромережевих модулів виявлення та класифікації, визначення глибини залягання та розкриття дефектів було створено три додаткові комп'ютерні моделі навчальних зразків з п'ятишарового вуглепластику. Кожна модель навчального зразка має аналогічні до моделі тестового зразка габаритні розміри та містить штучні дефекти певного конкретного типу. Дефекти всередині одного зразка відрізняються за поперечними розмірами (від 10 мм до 4 мм), глибинами залягання та значеннями розкриття (від 1 мм до 3 мм). Таке компонування дефектів дозволяє розширити різноманіття навчальних прикладів. На рис. 3.15 показана схема типового навчального зразка.

Для кожного навчального зразка було проведено моделювання процесу активного ТНК в умовах, що ідентичні умовам контролю тестового зразка. В результаті моделювання отримано набори температурних профілів дефектів з різними параметрами. На рис. 3.16, а показано приклад температурних профілів бездефектної ділянки так дефектів у вигляді повітряних порожнин різного розкриття на глибині залягання 1 мм.

На рис. 3.16, б показані диференціальні температурні сигнали від дефектів у вигляді повітряних порожнин розкритвом 1 мм на різних глибинах залягання.

Оптимальний час спостереження збільшується зі збільшенням глибини дефекту. Значення температурного сигналу ΔT також в даному збільшується зі зростанням глибини, але це пов'язане з тим, що температурні сигнали обчислені для дефектів різних поперечних розмірів. Для зразків, які містять штучні дефекти у вигляді алюмінієвих та паперових включень, отримано аналогічні дані.




Рис. 3.15. Схема моделі типового навчального зразка з п'ятишарового вуглепластику




Рис. 3.16. Результати моделювання ТНК навчального зразка, що містить дефекти у вигляді повітряних порожнин: а) – температурні профілі дефектів різного розкриву, б) – температурні сигнали від дефектів на різних глибинах

Вибірка температурних профілів формувалась із сигналів від всіх штучних дефектів, які містились в навчальному зразку. Промодельована послідовність термограм була експортована з програми COMSOL Multiphysics до текстового файлу. Дані у файлі представлені у вигляді матриці розміром $P \times Q$, де P – кількість пікселів термограми, яка подана у вигляді вектор-стовпця, Q – кількість термограм у послідовності. Таким чином, кожен рядок у даному файлі є вектором температурного профілю даного пікселя. Сформовані набори температурних профілів дефектів експортовано до середовища MATLAB для подальшої обробки.

Для створення навчальної вибірки була написана спеціальна функція. Вхідними аргументами є координати на термограмі прямокутної області $AB(i_1, j_1; i_2, j_2)$, яка містить необхідні зразки (дефектні або бездефектні пікселі), а також розмірність термограм ($M \times N$) та імпортований набір даних. Функція послідовно перетворює кожен термограму із початкового масиву з вектора-стовпця на двовимірну матрицю $M \times N$, виділяє дані із області за вказаними координатами, трансформує їх у вектор-стовпець та записує в окремий масив. Рядки в даному масиві є температурними профілями пікселів з області, координати якої вказані на вході функції. В результаті функція повертає масив температурних профілів необхідної ділянки. Далі отримані масиви об'єднуються в один та формують набір навчальних вхідних векторів (предикторів). До даного масиву додаються стовпці, які містять номери відповідних класів – формуються навчальні пари. Далі рядки у масиві даних перемішуються в випадковому порядку. Предиктори відділяються від номерів класів в окремий масив. В результаті, отримується два масиви – вхідних навчальних зразків у випадковому порядку та відповідних їм цілей.

Для нейромережевого модуля виявлення та класифікації дефектів навчальні пари складались з температурного сигналу від бездефектної ділянки або дефекту та відповідного йому коду класу. Клас №1 відповідає бездефектній ділянці, клас №2 – дефекту у вигляді повітряної порожнини, клас №3 – дефекту у вигляді паперового включення, клас №4 – дефекту у вигляді алюмінієвого включення. Для нейромережевих модулів визначення глибини залягання та розкриття дефектів навчальні пари сформовано у відповідності до розглянутих раніше алгоритмів.

Загальна кількість навчальних пар в отриманому наборі вхідних векторів склала 27933. З них: 14950 зразків температурних профілів із бездефектних ділянок, 6258 зразків профілів дефектів у вигляді повітряних порожнин, 3123 зразки профілів дефектів у вигляді алюмінієвих включень, 3494 зразки профілів дефектів у вигляді паперових включень. Отримана множина навчальних пар була розділена на навчальну, тестову та валідаційну підмножини у відповідності з описаними раніше принципами.

3.2.4. Обробка результатів комп'ютерного моделювання з використанням удосконаленого методу визначення характеристик дефектів

Першим етапом обробки отриманих даних для нового ОК є розробка і навчання нейронних мереж відповідних модулів. Для всіх нейромережевих модулів емпірично обрано архітектуру з двома прихованими прошарками; кількість нейронів у першому прихованому прошарку – 12, у другому – 4. Вхідний прошарок містить 50 нейронів, що відповідає кількості термограм у початковій послідовності. НМ виявлення та класифікації дефектів містить 4 нейрони у вихідному прошарку. Архітектура мереж для визначення глибини залягання і розкриття дефектів обрана аналогічно, з відмінністю у кількості нейронів вихідного прошарку – в даному випадку, відповіддю мережі є не код класу, а значення глибини залягання дефектів, тому використовується один вихідний нейрон. В якості функції активації нейронів на всіх прошарках обрано гіперболічний тангенс. Схема архітектури ядра нейромережевого модуля виявлення та класифікації дефектів показана на рис. 3.17.




Рис. 3.17. Архітектура нейронної мережі виявлення та класифікації дефектів

Для навчання всіх трьох мереж використовувався алгоритм Левенберга-Маркарда (англ. Levenberg-Marquardt). Гранична кількість епох навчання була встановлена на рівні 3000. Значення мінімального градієнту для продовження навчання становило 10^{-8} . Оскільки не існує єдиного підходу до обрання параметрів навчання НМ в активному ТНК, всі вказані значення встановлені емпірично.

Під час навчання алгоритм зворотного поширення помилки може потрапити в один із локальних мінімумів функції помилки, тому зазвичай проводиться навчання декількох НМ з однаковою архітектурою та вибір найбільш оптимальної з них. Для кожного модуля в однакових умовах було навчено 5 мереж однакової архітектури, з яких обрано найкращу. Навчання НМ проводилось на ПК з наступними характеристиками: процесор Intel Core i7 3770k з тактовою частотою 3,5 ГГц, оперативна пам'ять 16 ГБ, графічна карта NVidia GeForce GTX 760.

На рис. 3.18, а наведено графік зміни середньоквадратичної помилки мережі під час навчання НМ визначення та класифікації дефектів, на рис. 3.18, б – аналогічний графік для мережі визначення глибини залягання. Результати навчання НМ зведено до таблиці 3.1.

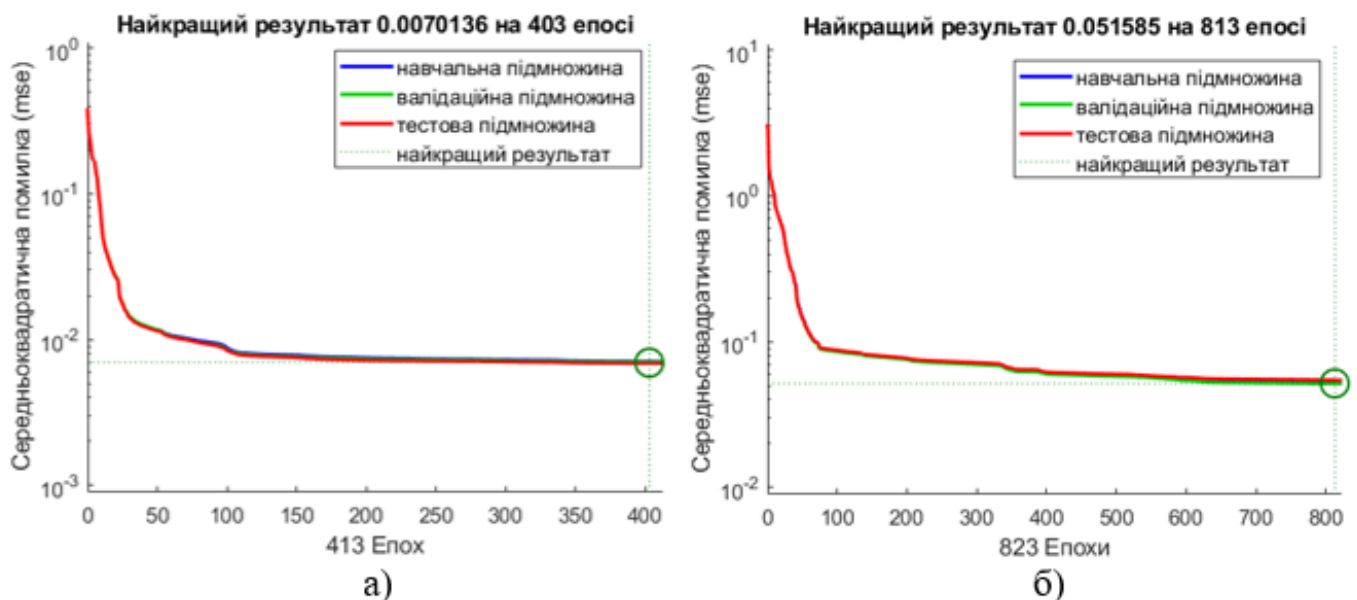


Рис. 3.18. Зміна MSE мережі під час навчання: а) – НМ класифікації дефектів, б) – НМ визначення глибини залягання дефектів

Таблиця 3.1. Результати навчання НМ

Задача мережі \ параметр	Час навчання, хв	Кількість епох	MSE
Класифікація дефектів	219	413	0,007
Визначення глибини	140	823	0,052
Визначення розкриву	142	870	0,037

На рис. 3.19, а показана карта дефектів, побудована за результатами роботи модуля виявлення та класифікації. На карті білим кольором зображено дефекти у вигляді повітряних порожнин, сірим – паперові включення, темно-сірим – алюмінієві включення. НМ забезпечила безпомилкову класифікацію дефектів. Форма та площа дефектів відтворені з високою достовірністю. На якісному рівні покращено відтворення дефектів у порівнянні з оптимальними термограмами. Кількісна оцінка точності визначення параметрів дефектів наведена в таблиці 3.2.

За результатами обробки відповідей модулів визначення глибини та розкриву дефектів побудовано теплову томограму за глибиною залягання та томограму внутрішньої структури ОК (рис. 3.19, б). У порівнянні з томограмою, отриманою за методом ДТТ, нейромережеві модулі забезпечили відтворення форми та розмірів дефектів на більш якісному рівні. Глибини залягання визначені для всіх штучних дефектів з помітно більшою достовірністю. Однак, можна відмітити наявність аналогічних крайових ефектів на границях деяких дефектів. В розробленій системі передбачена можливість програмної фільтрації таких недоліків за допомогою вбудованого медіанного фільтру.

На рис. 3.20 зображено загальний вигляд передньої панелі розробленої автоматизованої системи визначення характеристик дефектів під час контролю комп'ютерної моделі тестового зразка з багат шарового вуглепластику. Карта дефектів, просторова орієнтація та вигляд термограм незначно відрізняються від показаних раніше внаслідок відмінності внутрішніх алгоритмів обробки зображень в середовищах MATLAB та LabVIEW. Показані на рисунку параметри дефекту були визначені для повітряної порожнини розміром 10 мм та розкритом 1 мм, яка закладена на глибині залягання 1 мм.

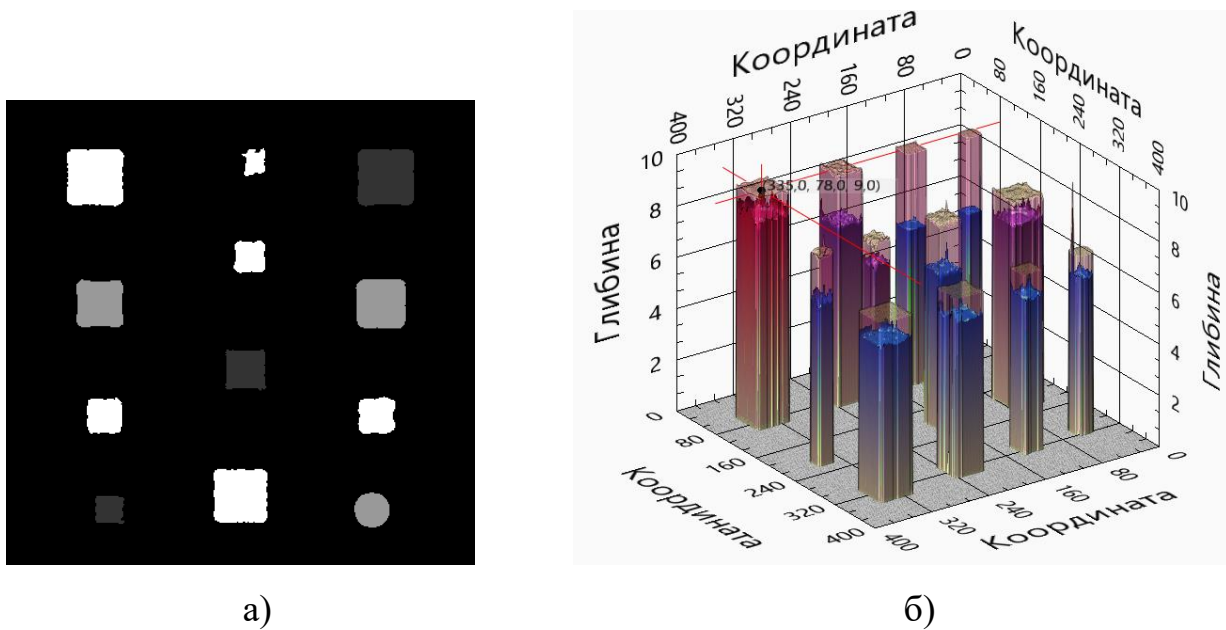


Рис. 3.19. Результати обробки послідовності термограм нейромержевими модулями: а) – карта дефектів, б) – внутрішня структура ОК

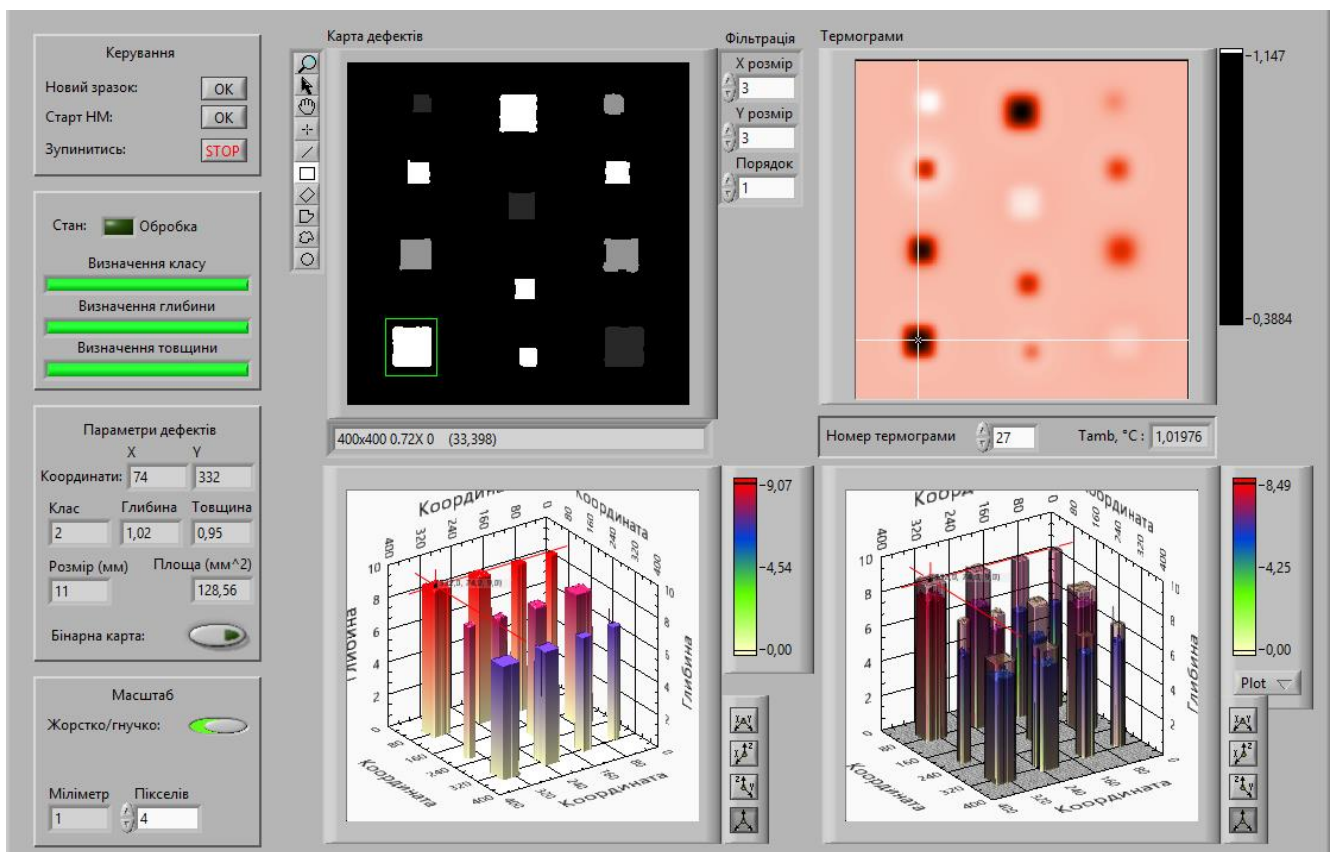


Рис. 3.20. Передня панель розробленої системи під час обробки даних комп'ютерного моделювання багатошарового ОК

3.2.5. Оцінка та аналіз результатів моделювання

За результатами комп'ютерного моделювання активного ТНК пластини з п'ятишарового вуглепластику вдалося виявити всі приховані штучні дефекти, які було закладено в модель тестового зразка. Нейромережевий модуль виявлення та класифікації дефектів дає найбільш точні результати у порівнянні з іншими методами обробки послідовностей термограм. Окрім того, наразі це єдиний з розглянутих методів, який дозволяє провести автоматичну класифікацію дефектів за типом.

Помилка класифікації температурних профілів оцінювалась за формулою (2.8), тоді як узагальнено нейромережевий модуль забезпечив безпомилкове розпізнавання класу дефектів. Варто зазначити, що результати роботи нейромережевих модулів справедливі лише для НМ, побудованих і навчених за методикою пп. 3.2.3-3.2.4. Внаслідок особливостей роботи технологій штучного інтелекту, у випадку перенавчання мереж кількісні параметри якості роботи НМ можуть коливатись в певних невизначених границях. Однак, дані коливання зазвичай не перевищують десятих частин відсотка [125].

За результатами аналізу, виявлені дефекти загалом класифіковані безпомилково. Помилка класифікації всіх температурних профілів в точках ОК складає 10,52 %. На основі відповіді нейромережевого модуля побудована карта дефектів за типами. Значення критерію Танімото для побудованої карти склало 89,48 %, що є найкращим показником серед розглянутих методів. Нейромережевий класифікатор на даному етапі розвитку є єдиним засобом для автоматичної побудови карт типів дефектів.

Методи Фур'є- та вейвлет-аналізу в розглянутій задачі мають схожу результативність. У порівнянні з оптимальними термограмами, значення критерію Танімото 73,16 % у випадку застосування методу аналізу Фур'є дозволяють покращити точність визначення форми і поперечних геометричних розмірів дефектів. Фазограми вейвлет-образів мають значний рівень сторонніх завад, а

побудована на основі ампліграм бінарна карта дефектів також не забезпечує підвищення точності у порівнянні з оптимальними термограмами.

Бінарна карта, побудована за МАГК, містить незначний артефакт в околі дефекту розміром 6 мм. Внаслідок цього, значення критерію Танімото складає 67,70 %, що поступається методам Фур'є, вейвлет і нейромережевим модулям. Зображення головних компонент є подібними до оптимальних термограм. Застосування МАГК призвело до збільшення похибки визначення розмірів дефектів у порівнянні з аналогічним параметром для оптимальних термограм. Критерій Танімото для МАГК у розмірі 67,70 % є одним із найгірших серед розглянутих методів.

Таблиця 3.2. Кількісна оцінка результатів обробки промодельованої послідовності термограм різними методами

Критерій\метод	Опт. термограма	Фур'є ан.	Вейв. аналіз	МАГК	ДТТ	НМ
Кількість виявлених дефектів на карті	12	12	12	12	12	12
Помилка класифікації температурних профілів, %	–	–	–	–	–	10,52
Критерій Танімото,%	73,11	73,16	69,73	67,70	60,82	89,48
Середньоквадратична похибка визначення глибини, мм	–	–	–	–	±0,35	±0,13
Гранична відносна похибка визначення глибини, %	–	–	–	–	±14,91	±7,97
Середньоквадратична похибка визначення розкриву, мм	–	–	–	–	–	±0,02
Гранична відносна похибка визначення розкриву, %	–	–	–	–	–	±2,41

В задачі визначення глибини залягання дефектів найкращі результати демонструє відповідний нейромережевий модуль. Гранична відносна похибка визначення глибини склала $\pm 7,97\%$ для нейромережевого модуля та $\pm 14,91\%$ для методу ДТТ. Отримана за методом ДТТ теплова томограма за глибинами залягання внаслідок наявності крайових ефектів є малоінформативною та містить артефакти. На аналогічній тепловій томограмі, побудованій на основі відповідей нейромережевого модуля, форма та глибина залягання дефектів відтворені з більшою точністю.

Побудована за результатами роботи нейромережевого модуля визначення розкриву дефектів теплова томограма внутрішньої структури ОК забезпечує визначення розкриву з граничною відносною похибкою до $\pm 2,41\%$. На сьогоднішній день, використання нейронних мереж є найбільш ефективним засобом для автоматизованої побудови такого роду томограм.

3.3. Дослідження впливу архітектури нейронних мереж, параметрів навчання та характеристик навчальної вибірки на результативність системи

Комп'ютерне моделювання дозволяє провести оцінку ступеню впливу різних параметрів нейронних мереж та навчального набору даних на ефективність роботи розробленої автоматизованої системи визначення характеристик дефектів. Завдяки створенню відповідних комп'ютерних моделей, можливе варіювання такими параметрами навчальної вибірки, як її обсяг, репрезентативність, кількість термограм у послідовності тощо. Це є значною перевагою у випадку відсутності можливості виготовлення великої кількості фізичних тестових зразків. Під час проведення досліджень, за основу обрано результати комп'ютерного моделювання активного ТНК тестового зразка з п'ятишарового вуглепластику. Умови контролю та параметри ОК не змінювались.

У випадку оцінки впливу параметрів мережі або навчання на результативність роботи системи, в якості критеріїв обрано час навчання, середньоквадратичну помилку мережі (MSE), а також критерій Танімото та кількісні оцінки похибок вимірювання характеристик дефектів .

3.3.1. Дослідження впливу кількості прихованих прошарків та кількості нейронів на результативність системи

Архітектура нейромережевих модулів під час тестування розробленої автоматизованої системи на даних комп'ютерного моделювання обиралась на основі рекомендацій, описаних в п. 2.2.3. На даний час не проводилось досліджень впливу архітектури НМ на ефективність її роботи в задачах активного ТНК. Певною мірою це пов'язано з тим, що архітектура мережі може відрізнитись для кожної конкретної задачі. Тому для формування рекомендацій щодо вибору архітектури мережі необхідно встановити початкові умови у вигляді параметрів ОК, умов контролю та поставлених задач [126]. Надалі розглядається вплив різних архітектур НМ на результати обробки даних, отриманих під час комп'ютерного моделювання, описаного в п. 3.2.1.

В розглянутому вище випадку, в якості ядр нейромережевих модулів використовувались багатошарові НМ прямого розповсюдження зі зворотним поширенням помилки. Кожна така мережа мала у своєму складі два прихованих прошарки. Кількість нейронів в першому прихованому прошарку Np_1 становила 12, кількість нейронів у другому прихованому прошарку $Np_2 = 4$.

В теорії штучних нейронних мереж існує твердження, згідно з яким будь-яка багатошарова НМ може бути зведена до одношарової НМ, що складається з вхідного, одного прихованого та вихідного прошарків. Однак, не існує рекомендацій щодо вибору кількості нейронів в прихованому прошарку для даного випадку. У разі зведення архітектури мережі до одношарової, загальна кількість нейронів, необхідних для забезпечення сталого рівня точності, значно збільшується (в залежності від кількості прихованих прошарків, що скорочуються) [127].

Для дослідження ефективності роботи нейромережевих модулів у випадку зведення архітектури НМ до одного прихованого прошарку, створено та навчено декілька мереж з різним числом прихованих нейронів Np . Результати тестування їх роботи зведено до таблиць 3.3-3.4. Для кожної розглянутої архітектури навчання мережі проводилось по п'ять разів. В таблицях наведені дані для найкращої за

отриманими показниками мережі. Як видно з таблиці 3.3, зі збільшенням числа нейронів у прихованому прошарку для мережі виявлення та класифікації дефектів зростає ефективність роботи. Однак, збільшення числа нейронів призводить до багаторазового збільшення часу навчання. Тому для даних задач рекомендується або обирати архітектуру з числом нейронів не більше 16, або використовувати мережу лише для однотипних ОК, що не вимагатиме повторного навчання.

Таблиця 3.3. Ефективність НМ виявлення та класифікації дефектів в залежності від кількості нейронів в одному прихованому прошарку

Критерій	$Np = 4$	$Np = 8$	$Np = 16$	$Np = 24$	$Np = 32$
Час навчання, хв	7	35	352	637	946
MSE мережі	0,0088	0,0080	0,0067	0,0063	0,0061
Помилка класифікації температурних профілів, %	16,81	14,87	13,39	12,78	12,46
Критерій Танімото, %	83,32	85,19	86,69	87,11	87,23

Таблиця 3.4. Ефективність НМ визначення глибини та розкриття дефектів в залежності від кількості нейронів в одному прихованому прошарку

Критерій	$Np = 4$	$Np = 8$	$Np = 16$	$Np = 24$	$Np = 32$
Час навчання мережі визначення глибини, хв	5	28	165	742	981
MSE мережі визначення глибини	0,073	0,064	0,043	0,053	0,051
Гранична відносна похибка визначення глибини, %	$\pm 21,57$	$\pm 11,69$	$\pm 4,78$	$\pm 4,56$	$\pm 4,31$
Час навчання мережі визначення розкриття, хв	16	54	112	713	901
MSE мережі визначення розкриття	0,056	0,053	0,039	0,037	0,038
Гранична відносна похибка визначення розкриття, %	$\pm 16,74$	$\pm 8,46$	$\pm 3,10$	$\pm 2,79$	$\pm 3,03$

Для мереж визначення глибини залягання та розкриття дефектів збільшення числа нейронів дозволяє покращити точність лише до певної межі. У випадку числа нейронів $Np > 16$, зростання точності вимірювання параметрів дефектів припиняється. Водночас, помітно збільшується час навчання. Отже, для вирішення даних задач ефективним є число нейронів в прихованому прошарку не більше 16.

На карті, яка побудована за результатами роботи мережі, що містить 4 нейрони в прихованому прошарку, форма дефектів має нечіткі границі. Карта дефектів, побудована мережею, яка містить 32 нейрони в прихованому прошарку, забезпечує найбільш точну відповідність теплових відбитків дефектів їх істинним розмірам та формі.

Зважаючи на складність прихованих взаємозв'язків у вхідних наборах даних активного ТНК, доцільним є використання архітектури багатошарової мережі з двома прихованими прошарками. Це поглиблює узагальнюючі властивості мережі, що робить її більш універсальною. В той же час, доведено, що надмірне збільшення числа прихованих прошарків не призводить до підвищення ефективності НМ. Навпаки, занадто ускладнена архітектура може призвести до перенавчання, що погіршить апроксимуючі властивості мережі [128].

На сьогоднішній день питання вибору оптимальної кількості нейронів в прихованих прошарках для НМ в активному ТНК є недостатньо дослідженим. У зв'язку з цим, проведемо дослідження впливу кількості нейронів в прихованих прошарках на результативність нейромережевих модулів в задачах обробки даних комп'ютерного моделювання активного ТНК розглянутої п'ятишарової пластини з вуглепластику. Для цього реалізовано та навчено декілька архітектур НМ з різним числом нейронів в прихованих прошарках, результати роботи яких показані в таблицях 3.5-3.6. В таблицях Np_1 – кількість нейронів в першому прихованому прошарку, Np_2 – кількість нейронів у другому прихованому прошарку.

Таблиця 3.5. Ефективність НМ виявлення та класифікації дефектів в залежності від кількості нейронів в двох прихованих прошарках

Критерій	$Np_1 = 3$ $Np_2 = 1$	$Np_1 = 6$ $Np_2 = 2$	$Np_1 = 12$ $Np_2 = 4$	$Np_1 = 18$ $Np_2 = 6$	$Np_1 = 24$ $Np_2 = 8$
Час навчання, хв	47	164	219	732	993
MSE мережі	0,0730	0,0214	0,0070	0,0068	0,0069
Помилка класифікації температурних профілів, %	48,05	23,15	10,52	9,47	10,08
Критерій Танімото, %	62,95	74,52	89,48	89,95	89,69

Таблиця 3.6. Ефективність НМ визначення глибини та розкриття дефектів в залежності від кількості нейронів в двох прихованих прошарках

Критерій	$Np_1 = 3$ $Np_2 = 1$	$Np_1 = 6$ $Np_2 = 2$	$Np_1 = 12$ $Np_2 = 4$	$Np_1 = 18$ $Np_2 = 6$	$Np_1 = 24$ $Np_2 = 8$
Час навчання мережі визначення глибини, хв	5	108	140	538	742
MSE мережі визначення глибини	0,162	0,084	0,052	0,050	0,052
Гранична відносна похибка визначення глибини, %	±24,19	±13,60	±5,07	±4,96	±5,31
Час навчання мережі визначення розкриття, хв	16	93	142	631	864
MSE мережі визначення розкриття	0,065	0,057	0,037	0,041	0,039
Гранична відносна похибка визначення розкриття, %	±5,05	±4,69	±2,41	±3,63	±3,12

Як видно з таблиці 3.5, ускладнення архітектури НМ виявлення та класифікації дефектів дозволяє покращити ефективність її роботи лише до комбінації $Np_1 = 12$ та $Np_2 = 4$. Подальше збільшення числа нейронів в прошарках не призводить до значущого покращення точності та достовірності класифікації. Водночас, з ускладненням архітектури значно зростає час навчання.

Аналогічною є ситуація, показана в таблиці 3.6. Збільшення кількості нейронів в прихованих прошарках суттєво впливає на час навчання, однак дозволяє покращити точність дефектометрії лише до архітектури $Np_1 = 12$ та $Np_2 = 4$. Подальше збільшення кількості нейронів є недоцільним, оскільки не призводить до значущого зменшення похибок вимірювання.

Мережа, що має архітектуру $Np_1 = 3$ та $Np_2 = 1$, демонструє найгірші результати. Внаслідок її роботи виявлено лише 6 із 12 закладених в ОК штучних дефектів. Це свідчить про занадто просту архітектуру мережі, що не забезпечує необхідної достовірності. Ускладнення архітектури до $Np_1 = 24$ та $Np_2 = 8$ дозволяє покращити результати виявлення дефектів, але за кількісними оцінками така структура не є оптимальною.

3.3.2. Дослідження впливу алгоритмів навчання на характеристики нейронних мереж

Під час навчання НМ можуть використовуватись різні алгоритми модифікації синаптичних ваг. Такі алгоритми засновані на математичних методах оптимізації, та мають власні переваги і недоліки. Вибір оптимального алгоритму модифікації синаптичних ваг залежить від конкретної задачі. В активному ТНК на сьогоднішній день не проводився порівняльний аналіз ефективності різних алгоритмів навчання нейронних мереж для класифікації, визначення глибини залягання або розкриття дефектів.

Найбільш широко застосовуються наступні навчальні алгоритми:

- *trainlm* – алгоритм навчання НМ, який оновлює значення ваг та зміщень нейронів відповідно до методу оптимізації Левенберга-Маркарда. Вважається, що даний алгоритм часто є найшвидшим алгоритмом зворотного поширення. Тому він зазвичай застосовується в якості еталонного під час навчання нових НМ, хоча його реалізація потребує більше пам'яті у порівнянні з іншими. Повний опис алгоритму Левенберга-Маркарда наведено в [129]. Даний алгоритм є оптимальним для навчання нейромереж середнього розміру (до декількох сотень зв'язків між нейронами).

- *trainbfg* – алгоритм навчання НМ, який оновлює значення ваг та зміщень нейронів відповідно до квазіньютонівського методу Бroyдена – Флетчера – Гольдфарба – Шанно (англ. BFGS). Алгоритм BFGS описаний у [130]. Цей алгоритм вимагає більше обчислень на кожній ітерації та більше пам'яті, ніж методи спряженого градієнта. Водночас, метод потребує меншої кількості ітерацій для досягнення необхідної точності. Недоліком є необхідність у зберіганні матриці других похідних розмірністю $n \times n$, де n – кількість синаптичних ваг і зміщень мережі. Це робить даний алгоритм малоприматним для навчання складних НМ. Однак для невеликих мереж алгоритм *trainbfg* може бути ефективним.

- *trainbr* – алгоритм навчання НМ, який оновлює значення ваг та зміщень нейронів відповідно до модифікованого методу оптимізації Левенберга-Маркарда.

Алгоритм мінімізує комбінацію середньоквадратичних помилок та синаптичних ваг, а потім визначає найбільш оптимальну комбінацію для найкращих узагальнюючих властивостей мережі. Даний процес називається байєсовою регуляризацією. Байєсова регуляризація мінімізує лінійну комбінацію середньоквадратичних помилок та ваг і модифікує результати для отримання найкращих апроксимаційних властивостей НМ. Байєсова регуляризація детально описана в [131]. Для обчислення матриці других похідних та зміщень нейронів використовується зворотне поширення помилки. Кожна змінна коригується відповідно до методу Левенберга-Маркарда.

- *traingd* – алгоритм навчання НМ, який оновлює значення ваг та зміщень нейронів відповідно до методу найшвидшого спуску. Ваги та зміщення модифікуються в напрямку негативного градієнта функції помилки. Для визначення величини зміни ваг та зміщень, від’ємний градієнт помножується на коефіцієнт швидкості навчання. Чим більша швидкість навчання, тим більший крок. Якщо коефіцієнт навчання занадто великий, алгоритм стає нестабільним. Якщо коефіцієнт швидкості навчання занадто малий, алгоритму знадобиться тривалий час для спуску до мінімуму. Детальніше алгоритм методу описано в роботі [132].

- *trainrp* – алгоритм навчання НМ, який оновлює значення ваг та зміщень нейронів відповідно до алгоритму стійкого зворотного розповсюдження (англ. Rprop). *trainrp* може бути використаний для навчання будь-якої мережі, синаптичні ваги, вхідні дані та передатні функції якої мають похідні. Для обчислень похідних та значень змін синаптичних ваг і зміщень використовується зворотне поширення помилки. Метою алгоритму навчання стійкого зворотного розповсюдження (Rprop) є усунення шкідливих впливів величин часткових похідних. Тільки знак похідної може визначати напрямок оновлення ваг, тоді як величина похідної не впливає на оновлення ваг. Величина зміни ваг визначається окремим значенням змінної оновлення. У випадку, коли ваги коливаються, величина зміни ваг зменшується. Якщо ваги продовжують змінюватися в одному

напрямку протягом кількох ітерацій, величина зміни ваг збільшується. Повний опис алгоритму Rprop наведено в [133].

З метою дослідження ефективності розглянутих алгоритмів, було проведено навчання НМ всіх нейромережових модулів системи із використанням наведених вище методів. В якості архітектури мережі обрано структуру з двома прихованими прошарками. Кількість нейронів в першому прихованому прошарку $Np_1 = 12$, в другому прихованому прошарку $Np_2 = 4$.

Для навчання використовувалась множина навчальних векторів, описана в п. 3.2.3. Обладнання та параметри навчання, які застосовувались під час дослідження, є аналогічними описаним у п. 3.2.4. Для кожного із досліджуваних алгоритмів проведено по 5 повних циклів перенавчання. Оцінка усереднених результатів навчання всіх нейромережових модулів наводиться в таблицях 3.7-3.8.

Таблиця 3.7. Результати навчання НМ виявлення та класифікації дефектів із застосуванням різних навчальних алгоритмів

Критерій\алгоритм	<i>trainlm</i>	<i>trainbfg</i>	<i>trainbr</i>	<i>traingd</i>	<i>trainrp</i>
Час навчання, хв	219	11	10	240	45
Кількість епох	413	642	487	515	9986
MSE мережі	0,0070	0,0136	0,0127	0,0071	0,118

Таблиця 3.8. Результати навчання НМ визначення глибини та розкриття дефектів із застосуванням різних навчальних алгоритмів

Критерій\алгоритм	<i>trainlm</i>	<i>trainbfg</i>	<i>trainbr</i>	<i>traingd</i>	<i>trainrp</i>
Час навчання мережі визначення глибини, хв	140	10	92	37	10
Кількість епох навчання мережі визначення глибини	823	748	941	9112	2231
MSE мережі визначення глибини	0,052	0,076	0,053	0,224	0,166
Час навчання мережі визначення розкриття, хв	142	12	51	41	23
Кількість епох навчання мережі визначення глибини	870	953	754	9357	3211
MSE мережі визначення розкриття	0,037	0,071	0,040	0,201	0,148

На основі даних з таблиці 3.7 можна зробити висновок, що найбільш оптимальним алгоритмом навчання мережі виявлення та класифікації дефектів за показником точності є алгоритм Левенберга-Маркарда. Середньоквадратична помилка мережі, навченої за даним алгоритмом, складає 0,0070. Найближчим до цього значення є результат навчання з використанням алгоритму найшвидшого спуску ($MSE = 0,0071$). Алгоритми BFGS та байєсової регуляризації є найбільш швидкодіючими, але мають більш високу помилку за результатами навчання. Алгоритм стійкого зворотного розповсюдження демонструє найгірші результати, зокрема, середньоквадратичну помилку мережі на рівні 0,118.

За таблицею 3.8, найкращі результати за показником середньоквадратичної помилки мережі має алгоритм Левенберга-Маркарда ($MSE = 0,052$ для глибини та $MSE = 0,037$ для розкриву). Близьким до нього за значеннями помилки є алгоритм байєсової регуляризації, який має більш високу швидкодію. Алгоритм BFGS є найкращим за часом навчання, але поступається за рівнем MSE (0,076 для глибини та 0,071 для розкриву). Алгоритми найшвидшого спуску та стійкого зворотного розповсюдження мають найменшу точність та потребують великої кількості ітерацій для завершення навчання, тому не рекомендуються для використання в зазначених задачах.

3.3.3. Дослідження впливу обсягу та якості навчальної вибірки на результати роботи системи

Важливим етапом під час створення нейромережових систем є оптимальне формування навчальної вибірки. Кількість навчальних пар, що відповідають різним типам дефектів або зразкам сигналів від одного дефекту, має безпосередній вплив на репрезентативність навчальної множини [134]. В розглянутих прикладах, для навчання НМ відповідних нейромережових модулів використовувались температурні профілі всіх точок штучних дефектів, закладених у навчальні зразки пластин із п'ятишарового вуглепластику. Наприклад, в отриманій послідовності термограм дефект із поперечним розміром 10 x 10 мм на зображенні має розмір 40 x 40 пікселів, і відповідно містить 1600 температурних профілів. Однак, завдяки

узагальнюючим властивостям НМ, немає необхідності представлення мережі під час навчання абсолютно всіх отриманих навчальних сигналів [135].

В таблицях 3.9-3.10 наведені результати навчання нейромережевих модулів з використанням різного обсягу навчальної вибірки $N_{\text{в}}$. Архітектура мереж та параметри навчання обрані аналогічними описаним в п. 3.3.4. Під час формування досліджуваних вибірок зберігався принцип репрезентативності. Скорочувалось лише число температурних профілів, якими описані дефекти кожного типу із кожним значенням глибини та розкриву.

Як видно з таблиці 3.9, зменшення обсягу навчальної вибірки в 4 рази (до кількості навчальних пар $N_{\text{в}} = 7000$) призводить до незначного погіршення точності визначення розмірів дефектів та достовірності класифікації температурних профілів (з помилкою до 14,32 %) у порівнянні з мережею, навченою за базовим набором. Подальше зменшення обсягу навчальної множини призводить до значного погіршення всіх показників роботи мережі. Водночас, час навчання також стрімко зменшується. Отже, з метою покращення достовірності класифікації та точності визначення форми дефектів не рекомендується зменшувати обсяг навчальної вибірки.

Таблиця 3.9. Ефективність НМ виявлення та класифікації дефектів в залежності від обсягу навчальної вибірки

Критерій	$N_{\text{в}} = 27933$	$N_{\text{в}} = 7000$	$N_{\text{в}} = 350$	$N_{\text{в}} = 140$
Час навчання, хв	219	52	4	1
Кількість епох навчання	413	161	104	70
MSE мережі	0,0070	0,0079	0,0081	0,0668
Кількість виявлених дефектів	12	12	12	9
Помилка класифікації температурних профілів, %	10,52	14,32	23,44	52,44
Критерій Танімото, %	89,48	81,93	76,83	60,86

Таблиця 3.10. Ефективність НМ визначення глибини та розкриття дефектів в залежності від обсягу навчальної вибірки

Критерій	<i>N_e</i> = 27933	<i>N_e</i> = 7000	<i>N_e</i> = 350	<i>N_e</i> = 140
Час навчання мережі визначення глибини	140 хв	28 хв	0 хв 44 с	0 хв 12 с
Кількість епох навчання мережі визначення глибини	823	370	181	84
MSE мережі визначення глибини	0,052	0,053	0,052	0,110
Гранична відносна похибка визначення глибини, %	±7,97	±22,71	±24,53	±42,97
Час навчання мережі визначення розкриття	142 хв	20 хв	0 хв 45 с	0 хв 4 с
Кількість епох навчання мережі визначення розкриття	870	306	195	50
MSE мережі визначення розкриття	0,037	0,041	0,052	0,106
Гранична відносна похибка визначення розкриття, %	±2,41	±3,11	±4,37	±10,09

Аналогічними є результати для НМ визначення глибини та розкриття дефектів. Для мережі визначення глибини залягання зменшення обсягу вибірки в 80 разів не призводить до зростання середньоквадратичної помилки мережі, однак помітно впливає на розмір відносної похибки визначення глибини, яка збільшується в 3 рази (з ±7,97 % до ±24,53 %). Для мережі визначення розкриття дефектів результати є аналогічними.

Значний вплив на ефективність роботи НМ має репрезентативність навчальної вибірки. В описаних раніше прикладах, для навчання нейромережових модулів виявлення та класифікації, визначення глибини залягання та розкриття дефектів тестового зразка з п'ятишарового вуглепластику в складі навчальної вибірки використовувались температурні профілі всіх 12 штучних дефектів, які були закладені в ОК, а також бездефектних ділянок. Однак, узагальнюючі властивості НМ дозволяють проводити навчання на обмеженій кількості прикладів сигналів. В такому випадку погіршується репрезентативність вибірки, але кількісні

дослідження впливу якості навчальної множини на результати обробки послідовностей термограм на сьогоднішній день не проводились.

З метою проведення відповідних досліджень, було реалізовано та навчено по п'ять моделей НМ, з яких обрано найкращу. Архітектура мереж та параметри навчання обрані аналогічними описаним в п. 3.2.4. Репрезентативність вибірки змінювалась шляхом вибору кількості дефектів N_d , зразки температурних профілів яких включаються до навчальної множини. Значення $N_d = 2$ означає, що до навчальної вибірки включено зразки температурних профілів від двох дефектів кожного типу. Відповідно, при $N_d = 1$ до складу навчальної вибірки включено зразки від одного дефекту кожного типу. Результати зведені до таблиць 3.11-3.12.

Для мереж визначення глибини залягання та розкриття дефектів зниження репрезентативності навчальної вибірки не призводить до однозначного підвищення MSE мережі. Однак, похибки визначення даних параметрів в такому випадку зростають (для мережі визначення глибини залягання з $\pm 7,97\%$ до $\pm 14,14\%$ у випадку $N_d = 1$; для мережі визначення розкриття з $\pm 2,41\%$ до $\pm 13,24\%$ у випадку $N_d = 1$). Для всіх мереж зі зниженням репрезентативності знижується і час навчання, оскільки зменшується обсяг навчальної вибірки. В цілому, навмисне скорочення репрезентативності навчальної множини не рекомендується, оскільки разом зі зменшенням часу навчання помітно зростають похибки визначення параметрів дефектів.

Таблиця 3.11. Ефективність НМ виявлення та класифікації дефектів в залежності від репрезентативності навчальної вибірки

Критерій	<i>Всі дефекти</i>	$N_d = 2$	$N_d = 1$
Час навчання, хв	219	121	65
Кількість епох навчання	413	390	256
MSE мережі	0,0070	0,0077	0,0081
Кількість виявлених дефектів	12	11	10
Помилка класифікації температурних профілів, %	10,52	15,71	19,09
Критерій Танімото, %	89,48	86,94	80,96

Таблиця 3.12. Ефективність НМ визначення глибини та розкриття дефектів в залежності від репрезентативності навчальної вибірки

Критерій	<i>Всі дефекти</i>	<i>Nδ = 2</i>	<i>Nδ = 1</i>
Час навчання мережі визначення глибини, хв	140	103	80
Кількість епох навчання мережі визначення глибини	823	847	869
MSE мережі визначення глибини	0,052	0,054	0,050
Гранична відносна похибка визначення глибини, %	$\pm 7,97$	$\pm 12,19$	$\pm 14,14$
Час навчання мережі визначення розкриття, хв	142	81	40
Кількість епох навчання мережі визначення розкриття	870	754	421
MSE мережі визначення розкриття	0,037	0,042	0,028
Гранична відносна похибка визначення розкриття, %	$\pm 2,41$	$\pm 5,95$	$\pm 13,24$

3.3.4. Дослідження впливу кількості термограм у початковій послідовності на результативність системи

Як відомо, результати обробки послідовностей термограм методами Фур'є-аналізу та ДТТ сильно залежать від кількості термограм. Дані методи потребують сотень термограм, записаних з високою кадровою частотою [136]. На сьогоднішній день відсутні дослідження впливу кількості термограм у послідовності на результати обробки даних активного ТНК за допомогою НМ. Вивчення цього питання дозволить визначити вимоги до тепловізійного обладнання та методики проведення контролю із використанням розробленої системи.

В загальному випадку, кількість термограм N_m у послідовності за умов незмінного часу контролю пов'язана з частотою дискретизації отриманих температурних профілів в точках ОК. Більша кількість термограм, записаних за один і той же проміжок часу, дозволяє зменшити похибку дискретизацій та підвищити роздільну здатність традиційних методів. Зважаючи на узагальнюючі

властивості нейронних мереж, передбачається, що інтелектуальні системи мають менш жорсткі вимоги до кількості термограм у послідовності.

Із використанням комп'ютерного моделювання було записано декілька послідовностей термограм, що відображають процес активного ТНК тестового зразка з п'ятишарового вуглепластику в умовах, описаних в п. 3.2.1. В результаті моделювання отримано послідовності, що містять 20, 50, 80 та 100 термограм. Тривалість запису термограм залишалась незмінною і становила 15 с. Навчальні множини для нейромережових модулів формувались згідно з алгоритмами, описаними в п. 3.2.3. Для проведення дослідження, було проведено навчання п'яти моделей НМ для кожного нейромережового модуля, з яких обрано найкращі. Архітектура мереж та параметри навчання обрані аналогічними описаним в п. 3.3.4. Далі проводилось тестування роботи НМ в задачах виявлення та класифікації дефектів та визначення їх параметрів. Кількісна оцінка ефективності навчених НМ наводиться в таблицях 3.13-3.14.

Як видно з таблиці 3.13, зміна кількості термограм в початковій послідовності не має суттєвого впливу на результативність нейромережового модуля виявлення та класифікації дефектів. Середньоквадратична помилка мережі коливається в діапазоні $[0,0070; 0,0079]$, помилка класифікації температурних профілів змінюється в межах від 10,23 % до 11,41 %, значення критерію Танімото лежить в діапазоні $[88,37; 89,81]$. Зі збільшенням кількості термограм зростає час навчання мережі, оскільки збільшується кількість зв'язків між нейронами вхідного та першого прихованого прошарків.

Аналогічними є дані таблиці 3.14. Для НМ визначення глибини залягання дефектів MSE мережі лежить в границях $[0,051; 0,060]$, гранична відносна похибка визначення глибини складає від $\pm 7,97$ % до $\pm 9,17$ %. Середньоквадратична помилка мережі визначення розкриття складає від 0,035 до 0,045, відносна похибка від $\pm 2,27$ % до $\pm 3,21$ %. Отже, збільшення кількості термограм суттєво впливає на час навчання, та не має помітного впливу на ефективність роботи розглянутих нейронних мереж.

Таблиця 3.13. Ефективність НМ виявлення та класифікації дефектів в залежності від кількості термограм у початковій послідовності

Критерій	<i>Nm</i> = 20	<i>Nm</i> = 50	<i>Nm</i> = 80	<i>Nm</i> = 100
Час навчання, хв	47	219	310	482
Кількість епох навчання	312	413	484	401
MSE мережі	0,0079	0,0070	0,0073	0,0071
Кількість виявлених дефектів	12	12	12	12
Помилка класифікації температурних профілів, %	11,41	10,52	10,23	11,37
Критерій Танімото, %	88,37	89,48	89,81	89,01

Таблиця 3.14. Ефективність НМ визначення глибини та розкриття дефектів в залежності від кількості термограм у початковій послідовності

Критерій	<i>Nm</i> = 20	<i>Nm</i> = 50	<i>Nm</i> = 80	<i>Nm</i> = 100
Час навчання мережі визначення глибини, хв	35	140	264	351
Кількість епох навчання мережі визначення глибини	613	823	814	807
MSE мережі визначення глибини	0,059	0,052	0,060	0,051
Гранична відносна похибка визначення глибини, %	±9,17	±7,97	±8,11	±7,83
Час навчання мережі визначення розкриття, хв	62	142	293	376
Кількість епох навчання мережі визначення розкриття	678	870	742	840
MSE мережі визначення розкриття	0,045	0,037	0,035	0,039
Гранична відносна похибка визначення розкриття, %	±3,21	±2,41	±2,27	±3,10

Висновки до розділу 3

1. Проведено комп'ютерне моделювання активного ТНК тестового зразка у вигляді пластини з багатошарового вуглепластику, яка містить штучні внутрішні дефекти у вигляді повітряних порожнин, алюмінієвих та паперових включень різних розмірів на різних глибинах залягання. Для формування навчальної

множини проведено аналогічне комп'ютерне моделювання процесу активного ТНК навчальних зразків, що дозволило отримати набори температурних профілів дефектів всіх типів з різними параметрами. Встановлено, що розроблена система дозволяє виявити всі 12 дефектів та безпомилково класифікувати їх за типом.

2. Проведено порівняльний аналіз ефективності роботи розробленої системи та традиційних методів обробки послідовностей термограм в задачах обробки даних комп'ютерного моделювання активного ТНК пластини з багат шарового вуглепластику, в результаті якого встановлено, що:

– значення критерію Танімото за результатами обробки отриманих даних за допомогою розробленої системи становить 89,48 %, що є найкращим показником серед розглянутих методів (найближчий результат $T = 73,16$ % має Фур'є-аналіз);

– розроблена система дозволяє визначити глибину залягання дефектів з граничною відносною похибкою $\pm 7,97$ %, тоді як для методу ДТТ даний показник становить $\pm 14,91$ %;

– розкриття дефектів за допомогою розробленої системи було визначено з граничною відносною похибкою на рівні $\pm 2,41$ %.

3. Проведено дослідження впливу архітектури на результативність НМ в задачах активного ТНК пластини з багат шарового вуглепластику, в результаті якого:

– встановлено, що у випадку використання архітектури з одним прихованим прошарком, число нейронів в ньому більше 16 призводить до значного збільшення часу навчання (наприклад, з 352 до 637 хвилин у випадку збільшення числа нейронів з 16 до 24 для мережі виявлення та класифікації дефектів). Водночас, збільшення числа нейронів не призводить до значного покращення точності вимірювання параметрів дефектів (наприклад, для мережі визначення глибини залягання збільшення числа нейронів з 16 до 24 веде до покращення точності на 0,22 %).

– встановлено, що в разі використання архітектури з двома прихованими прошарками, час навчання значно збільшується зі збільшенням числа нейронів у

них (наприклад, для мережі виявлення та класифікації дефектів з архітектурою $Np_1 = 12$ та $Np_2 = 4$ час навчання становить 219 хвилин, а у випадку збільшення числа нейронів до $Np_1 = 16$ та $Np_2 = 8$ відповідний час зростає до 732 хвилин; водночас, в такому разі критерій Танімото покращується лише на 0,47%). Кількісні показники роботи НМ суттєво не покращуються у разі збільшення числа нейронів відносно архітектури $Np_1 = 12$ та $Np_2 = 4$;

– встановлено, що серед розглянутих варіантів найкращу точність визначення глибини залягання дефектів має мережа з одним прихованих прошарком і 32 нейронами в ньому. Найбільшу точність визначення розкриття дефектів має мережа з двома прихованими прошарками та кількістю нейронів в них $Np_1 = 12$ та $Np_2 = 4$.

– доведено, що обрана архітектура НМ з двома прихованими прошарками та кількістю нейронів в них на рівні $Np_1 = 12$ та $Np_2 = 4$ є найбільш оптимальною за сукупністю параметрів у порівнянні з іншими розглянутими архітектурами.

4. Досліджено вплив навчальних алгоритмів на ефективність НМ в задачах активного ТНК пластини з багатошарового вуглепластику. Встановлено, що найкращим за показником середньоквадратичної помилки мережі є навчальний алгоритм оптимізації за методом Левенберга-Маркарда. Мережа виявлення та класифікації дефектів, навчена за даним алгоритмом, має помилку $MSE = 0,007$. Мережі визначення глибини залягання та розкриття дефектів, навчені за даним алгоритмом, мають MSE на рівні 0,052 та 0,037 відповідно. Водночас, в ряді випадків інші алгоритми можуть забезпечити більшу швидкість навчання.

5. Проведено дослідження впливу обсягу навчальної вибірки на ефективність НМ. Встановлено, що зі значним зменшенням обсягу вибірки результативність нейромережових модулів погіршується. Наприклад, у разі зменшення обсягу вибірки з 27933 до 7000 зразків, помилка класифікації температурних профілів зростає на 5,94 %; значення критерію Танімото погіршується на 7,55 %; гранична відносна похибка визначення глибини залягання дефектів збільшується на 14,74 %, розкриття – на 0,7 %. Водночас, час навчання скорочується в 3-4 рази.

6. Досліджено вплив репрезентативності навчальної вибірки на ефективність НМ. Встановлено, що зі зменшенням репрезентативності погіршуються всі показники роботи системи, окрім часу навчання НМ. Наприклад, у випадку включення до навчальної вибірки сигналів не від всіх, а від двох дефектів кожного типу, кількість виявлених дефектів зменшиться з 12 до 11, помилка класифікації температурних профілів збільшиться на 5,19 %, значення критерію Танімото погіршується на 2,54 %, гранична відносна похибка визначення глибини залягання зростає на 4,22 %, розкриву – на 3,54 %. Проте, незначно скорочується час навчання.

7. Досліджено вплив кількості термограм у послідовності на результативність роботи нейромережових модулів. Встановлено, що зі збільшенням кількості термограм суттєво зростає час навчання. Однак, кількісні показники ефективності роботи НМ в такому випадку помітно не покращуються. Це свідчить про слабку залежність результативності системи від кількості термограм у послідовності, що є перевагою нейромережових систем.

8. В цілому, підтверджено високий рівень автоматизації та помітне підвищення точності визначення параметрів дефектів із використанням розробленої системи аналізу результатів активного ТНК із застосуванням удосконаленого методу визначення характеристик дефектів у порівнянні з класичними методами.

РОЗДІЛ 4

ЕКСПЕРИМЕНТАЛЬНІ ДОСЛІДЖЕННЯ ЕФЕКТИВНОСТІ АВТОМАТИЗОВАНОЇ КЛАСИФІКАЦІЇ ДЕФЕКТІВ ТА ДЕФЕКТОМЕТРІЇ УДОСКОНАЛЕНИМ МЕТОДОМ

З метою перевірки алгоритмів та оцінки роботи розробленої автоматизованої системи аналізу даних теплового контролю із використанням удосконаленого методу визначення характеристик дефектів було проведено експериментальні дослідження по виявленню і класифікації дефектів та дефектометрії тестових зразків з багатошарового склотекстоліту.

Склотекстоліти – листові КМ, які одержуються за допомогою гарячого пресування попередньо просочених волокнистих наповнювачів – паперів і тканин. Під час їх виробництва в якості основи застосовують спеціальні сорти просоченого паперу, бавовняні і безлужні скляні тканини. Для просочення наповнювачів використовуються сполучні на фенолоформальдегідній, поліефірній, епоксидній та інших хімічних основах [137]. Основними областями застосування є машино- та приладобудування, металургійна промисловість. Склотекстоліт застосовують для виготовлення шестерень, прокладок, панелей, щитів тощо. Також він використовується для виготовлення основних елементів конструкції легких літаків, наприклад, в контейнерах паливних баків літаків, під час виготовлення лопатей вертолітних гвинтів та лопаток двигуна [138].

Широке застосування склотекстоліту в якості матеріалу відповідальних деталей та вузлів робить актуальною задачу контролю його якості. Для перевірки ефективності роботи розробленої системи було створено декілька тестових зразків із багатошарового склотекстоліту, що містили штучні дефекти різних типів з відомими параметрами.

4.1. Дослідження зразків з багатошарового склотекстоліту

4.1.1. Розробка та виготовлення експериментальних зразків

З метою проведення експериментальних досліджень ефективності роботи системи автоматизованого аналізу теплових полів було розроблено два навчальних та один тестовий зразок з багатошарового склотекстоліту марки СТЕФ-221 (ГОСТ 12652-74). Даний матеріал використовується як конструкційний для виготовлення деталей відповідальних, що мають високі показники міцності. Розроблені зразки є пластинами квадратної з п'яти прошарків склопластику. Загальна товщина кожного зразка складає 5 мм, товщина одного прошарку – 1 мм. Сторона пластини дорівнює 100 мм. Зразки №1 та №2 є навчальними, зразок №3 використовується як тестовий. Зразки виготовлено на базі ІЕЗ ім. Є. О. Патона НАН України.

Схема тестового зразка №3 показана на рис. 4.1. Він містить приховані штучні дефекти трьох типів: повітряні порожнини (білий колір на рис. 4.1), паперові сторонні включення (червоний колір) та алюмінієві сторонні включення (синій колір). Дефекти мають квадратну форму, розмір сторони складає від 10 мм до 4 мм. Приховані штучні дефекти розташовані на глибинах залягання 1 мм, 2 мм та 3 мм. Окрім того, дефекти мають різні значення розкриву: 1 мм, 2 мм або 3 мм.




Рис. 4.1. Схема тестового зразка №1 з багатошарового склотекстоліту

Матеріал ОК виготовлених зразків має наступні теплофізичні властивості (за температури 20 °С):

- коефіцієнт теплопровідності: 0,3 Вт/м·К;
- питома теплоємність, 960 Дж/кг·К;
- густина: 1600 кг·м³.

Навчальний зразок №2 містить штучні дефекти у вигляді паперових та алюмінієвих включень з різними геометричними параметрами. Навчальний зразок №3 містить штучні дефекти лише у вигляді повітряних порожнин різної конфігурації. Внутрішня структура навчальних зразків відрізняється від тестового зразка та докладно описується в п. 4.1.4. На рис. 4.2 показано зовнішній вигляд тестового зразка №3.




Рис. 4.2. Зовнішній вигляд тестового зразка №3

4.1.2. Опис експерименту

Активний ТНК всіх виготовлених зразків проводився за схемою з двостороннім доступом до ОК, показаною на рис. 4.3. Зовнішній вигляд експериментальної установки показано на рис. 4.4.




Рис. 4.3. Схема експерименту

Під час проведення експерименту застосовувалась схема двостороннього активного ТНК, показана на рис. 4.3. Потужність інфрачервоного джерела нагріву становить 1 кВт, з яких безпосередньо на ОК припадає 326 Вт. Для мінімізації впливу на результати теплового випромінювання від джерела нагріву використовується сталева захисна пластина, яка містить отвір та кріплення для ОК. Пластина з ОК розташовується на відстані 100 мм від нагрівача. Відстань від ОК до тепловізора складає 400 мм.

В якості засобу реєстрації використовується тепловізор Testo 876, який має наступні основні характеристики:

- розмір матриці (детектору): 160 x 120 пікселів;
- роздільна здатність термограм: 360 x 240 пікселів;
- температурна чутливість: до 80 мК за температури 30 °С;
- похибка вимірювання температури: $\pm 2 \%$.



Рис. 4.4. Зовнішній вигляд експериментальної установки

Керування тепловізором та джерелом нагріву здійснюється оператором в ручному режимі. Температура навколишнього середовища під час проведення експериментальних досліджень становила 20 °С. На початку експерименту проводиться реєстрація термограми ОК в початковий момент часу. Після ввімкнення інфрачервоного нагрівача та виведення його на робочу потужність, розпочинається запис термограм. Часовий інтервал між сусідніми термограмами

становить 6 с. Нагрів та реєстрація експериментальної послідовності термограм проводиться протягом 120 с. Після завершення процедури запису термограм, нагрівач вимикається. В результаті експерименту отримано послідовність, що містить 20 термограм. Отримані результати відображають процес зміни теплового поля ОК на стадії нагріву. Контроль за даною методикою проводиться для всіх розроблених навчальних та тестового зразків.

Записані послідовності термограм були експортовані на ПК. Початкова обробка термограм здійснювалась за допомогою фірмового ПЗ Testo IRSoft. В якості кольорової шкали обрано кольори розжареного заліза. Роздільна здатність кожної з отриманих термограм складає 320 x 240 пікселів. Термограми збережено у вигляді зображень та відповідних масивів піксельних температур. Приклади термограм зразка №3 наведено в Додатку А. На базі отриманих результатів сформовано множину початкових даних для подальшої обробки. Термограма тестового зразка №3 в оптимальний час контролю показана на рис. 4.5.




Рис. 4.5. Термограма тестового зразка №3 в оптимальний час контролю

На оптимальній термограмі візуально можна чітко розрізнити 8 теплових відбитків штучних дефектів. Внаслідок значних крайових ефектів, інформація щодо дефектів нижнього ряду втрачається. Загалом, термограма ОК характеризується нерівномірністю нагріву, що ускладнює її автоматизовану обробку стандартними методами. Далі розглядається лише регіон інтересу, на якому зображено безпосередньо ОК.

На основі оптимальної термограми тестового зразка №3 в автоматичному режимі побудовано бінарну карту дефектів (рис. 4.6). На отриманому зображенні можна чітко розрізнити лише два прихованих дефекти. Інформація щодо інших дефектів була втрачена внаслідок процедури бінаризації за пороговим рівнем. На результати бінаризації значно вплинула нерівномірність нагріву.

На рис. 4.7, а показані зразки температурних профілів бездефектної ділянки та дефектів різного типу, що залягають на глибині 3 мм. Відповідні їм диференціальні температурні сигнали ΔT показані на рис. 4.7, б. Оптимальний час спостереження для дефектів різних типів в даному випадку співпадає, оскільки всі вони розташовані на однаковій глибині. Приклад диференціальних температурних сигналів від штучних дефектів зразка №7, які розташовані на різній глибині залягання, показано на рис. 4.7, в.

Експериментальні послідовності термограм характеризуються низькою візуальною якістю. Оператор може впевнено визначити менше половини із всіх прихованих дефектів. Однак, висока температурна чутливість тепловізійного обладнання дозволяє розрізнити температури в р точках ОК. Завдяки цьому, температурні профілі штучних дефектів мають більш достовірну форму та є подібними до результатів комп'ютерного моделювання. Отже, отримані дані можуть бути використані для подальшої цифрової обробки.




Рис. 4.6. Бінарна карта дефектів зразка №3

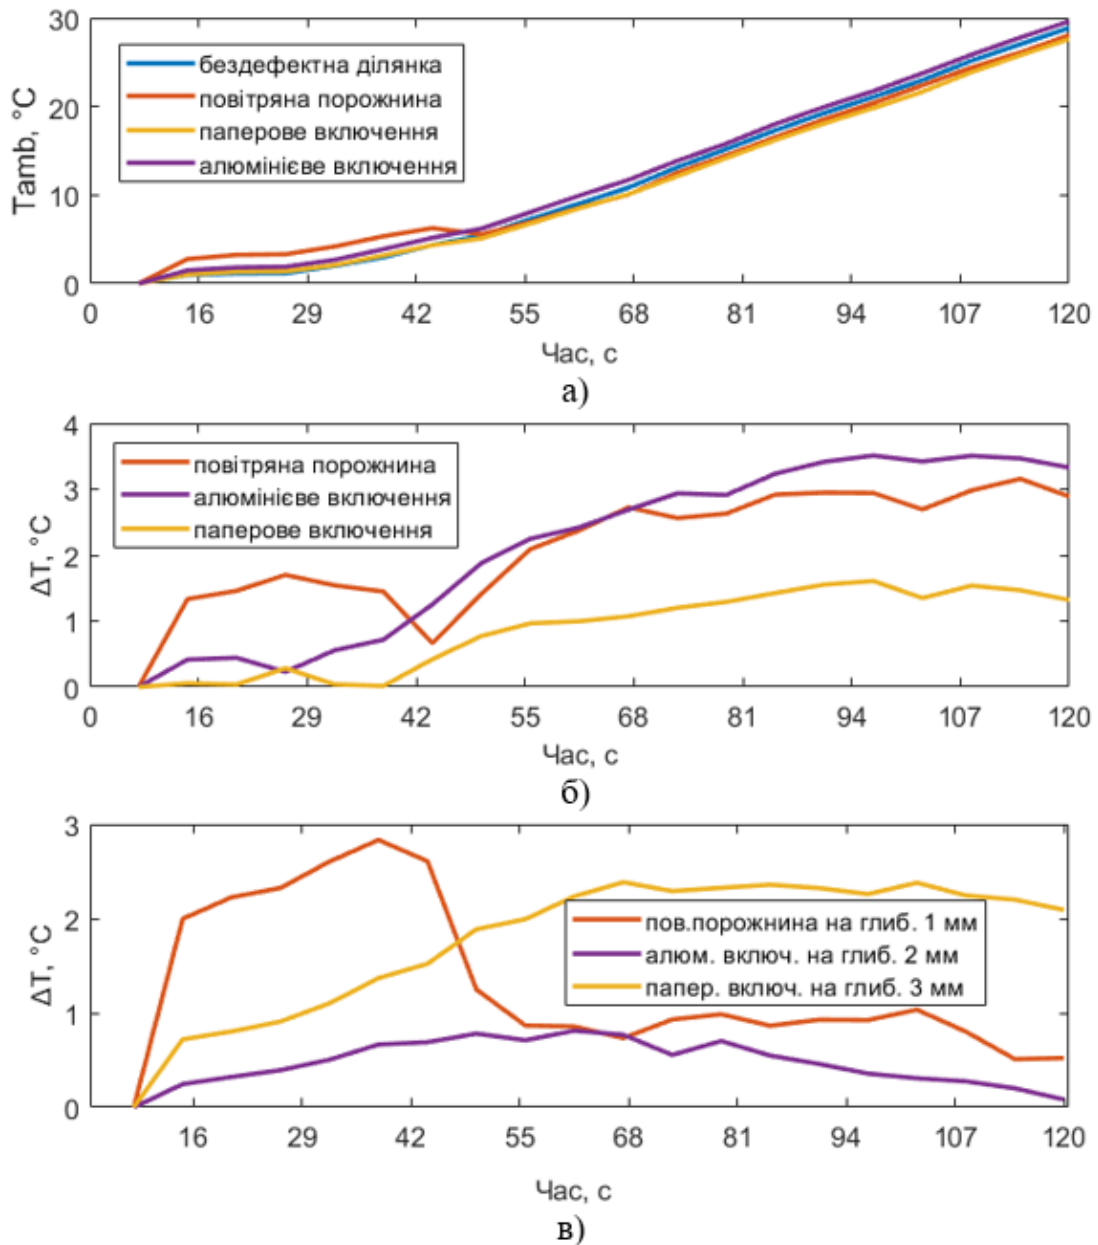


Рис. 4.7. Сигнали від бездефектної ділянки та дефектів для зразка №3:
 а) – температурні профілі на глибині залягання 3 мм, б) – диференціальні температурні сигнали на глибині 3 мм, в) – диференціальні температурні сигнали на різних глибинах

4.1.3. Обробка експериментальних даних традиційними методами

Застосуємо метод Фур'є-аналізу для обробки експериментальної послідовності термограм тестового зразка №3. Найбільш інформативними визначено ампліграму (рис. 4.8, а) та фазограму (рис. 4.8, б) на другій частоті. За вказаною ампліграмою візуально можна однозначно виділити теплові відбитки 10

прихованих штучних дефектів, які були закладені в зразок №3. У порівнянні з оптимальною термограмою, на якісному рівні помітне покращення співвідношення сигнал/шум на ампліграмі. Зображення фази Фур'є-образів в даному випадку є менш інформативними та не дозволяють покращити результати контролю.




Рис. 4.8. Результат Фур'є-аналізу зразка №3 на другій частоті: а) – ампліграма, б) – фазограма

На базі отриманих ампліграм, в автоматичному режимі побудована бінарна карта дефектів (рис. 4.9). Внаслідок нерівномірності нагріву та високого рівня завад, бінарна карта в даному випадку є малоінформативною.



Рис. 4.9. Бінарна карта дефектів зразка №3, побудована за результатами Фур'є-аналізу

В результаті обробки експериментальної послідовності термограм методом вейвлет-аналізу, отримано зображення амплітуд та фаз вейвлет-образів. На рис. 4.10, а показана ампліграма зразка №3 на десятій частоті. Зображення є малоінформативним та має більш низьку якість у порівнянні з оптимальною

термограмою. На рис. 4.10, б показано фазограму на восьмій частоті. На зображенні можна виявити положення деяких прихованих дефектів, але зробити однозначні висновки щодо їх форми та розміру неможливо. Аналогічно до попереднього експерименту, застосування вейвлет-перетворення для аналізу експериментальних послідовностей термограм не дозволяє отримати на якісному рівні більш достовірні результати контролю.




Рис. 4.10. Результат вейвлет-аналізу зразка №3: а) – ампліграма на 10-ій частоті, б) – фазограма на 8-ій частоті

На рис. 4.11 показана побудована в автоматичному режимі на базі результатів вейвлет-аналізу бінарна карта дефектів. Отримане зображення є подібним до отриманого за результатами Фур'є-аналізу експериментальної послідовності, та має аналогічні недоліки. На бінарній карті можна достовірно виявити положення лише двох штучних дефектів.




Рис. 4.11. Бінарна карта дефектів зразка №3, побудована за результатами вейвлет-аналізу

Застосуємо метод аналізу головних компонент для обробки експериментальної послідовності термограм зразка №3. На рис. 4.12, а показане зображення шостої головної компоненти, яке є найбільш інформативним. На зображенні мінімізується вплив нерівномірності нагріву, що дозволяє візуально виявити 11 штучних дефектів. У порівнянні з оптимальною термограмою, на якісному рівні покращено співвідношення сигнал/шум. Форма та розміри теплових відбитків правильно визначених дефектів є достовірними.

На рис. 4.12, б показано бінарну карту дефектів, яка була побудована в автоматичному режимі на основі зображення шостої головної компоненти. Нерівномірність нагріву внаслідок впливу крайових ефектів призводить до погіршення ефективності виявлення дефектів під час процедури бінаризації. Однак, у порівнянні з отриманими за іншими методами бінарними картами, нерівномірність нагріву в нижній частині зображення зведена до мінімуму. За отриманою картою достовірно визначено положення лише чотирьох прихованих дефектів, тоді як інші структури на зображенні є артефактами.




Рис. 4.12. Обробка послідовності термограм зразка №3 за МАГК: а) – шоста
головна компонента, б) – бінарна карта дефектів

В результаті обробки експериментальної послідовності термограм методом ДТТ отримано максіграму (рис. 4.13, а) та таймограму (рис. 4.13, б) тестового зразка №3. На максіграмі візуально можна однозначно виявити 8 прихованих дефектів. Співвідношення сигнал/шум на якісному рівні є кращим у порівнянні з

оптимальною термограмою, оскільки на отриманому зображенні можна більш впевнено виявити дефекти розміром 4 мм.

На рис. 4.14, а показана бінарна карта дефектів, побудована в автоматичному режимі на основі отриманих зображень. Теплова томограма ОК за глибиною залягання дефектів показана на рис. 4.14, б.




Рис. 4.13. Обробка послідовності термограм зразка №3 методом ДТТ:

а) – максіграма, б) – таймограма




Рис. 4.14. Результати обробки отриманих максіграми та таймограми зразка №3:

а) – бінарна карта дефектів, б) – теплова томограма

Бінарна карта дефекті, побудована за результатами обробки послідовності термограм методом ДТТ, є подібною до карти, отриманої за оптимальною термограмою. На карті достовірно визначено положення лише одного прихованого дефекту. Теплова томограма за глибиною залягання дефектів не відображає

достовірної внутрішньої структури ОК. На томограмі неможливо оцінити глибину залягання жодного із закладених в ОК штучних дефектів, тому кількісна оцінка точності визначення глибини для даного випадку неможлива.

4.1.4. Формування навчального набору експериментальних даних для нейромережевих модулів

З метою формування набору навчальних векторів для нейромережевих модулів, було розроблено та виготовлено навчальні зразки №1 та №2. Матеріал, структура та геометричні розміри навчальних зразків відповідають аналогічним параметрам тестового зразка №1. Процедура контролю навчальних зразків відбувалась за методикою та в умовах, описаних в п. 4.1.2 для зразка №1.

Навчальний зразок №1 містить штучні внутрішні дефекти у вигляді сторонніх алюмінієвих та паперових включень, що мають різні геометричні розміри, значення розкриву та глибини залягання l . Схема навчального зразка №1 показана на рис. 4.15. Синім кольором зображені дефекти у вигляді алюмінієвих включень, червоним – паперових включень. Загалом, для кожного типу дефектів створено по 6 штучних моделей. Штучні дефекти першої вертикальної лінії мають розкрив 3 мм та залягають на глибині 1 мм, другої вертикальної лінії – розкрив 2 мм та глибину залягання 1 мм та 2 мм, третьої вертикальної лінії – розкрив 1 мм та глибину залягання 1 мм, 2 мм та 3 мм.

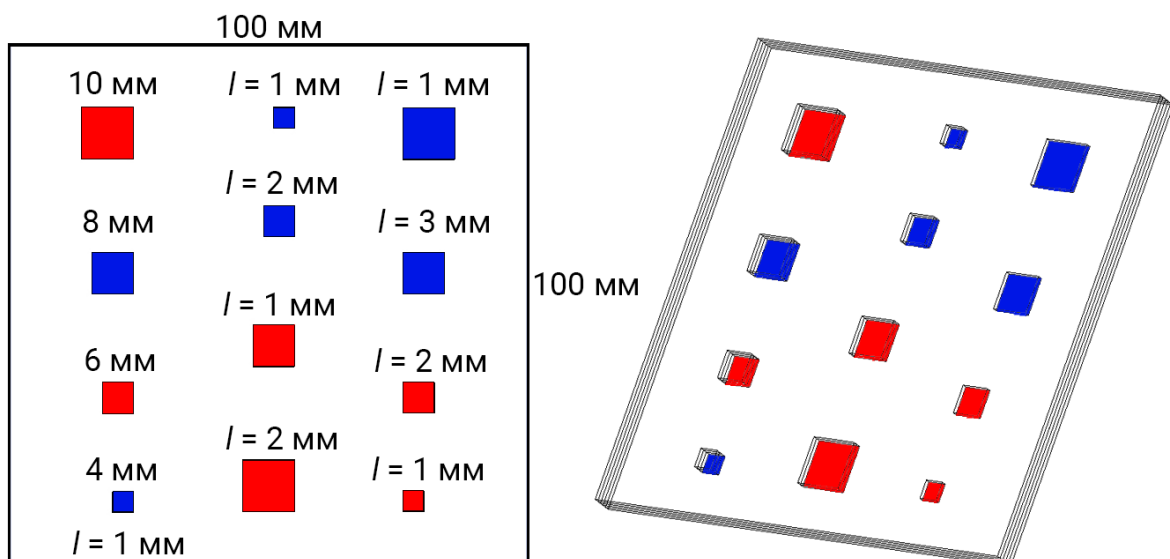


Рис. 4.15. Схема навчального зразка №5

Приклади температурних профілів бездефектної ділянки та дефектів зразка №1 різного типу, що мають розкриття 3 мм та глибину залягання 1 мм, показано на рис. 4.16. На рис. 4.17, а зображено приклади диференціальних температурних сигналів дефектів зразка №1 у вигляді алюмінієвих включень, що залягають на глибині 1 мм та мають різні значення розкриття. Аналогічні приклади для дефектів зразка №1 у вигляді паперових включень показано на рис. 4.17,б.




Рис. 4.16. Температурні профілі бездефектної ділянки та дефектів навчального зразка №1


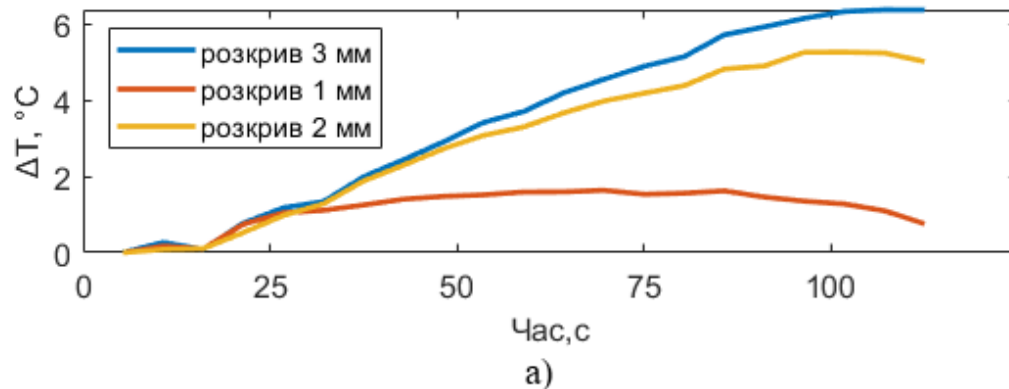


Рис. 4.17. Диференціальні температурні сигнали від дефектів навчального зразка №1 на глибині 1 мм: а) – алюмінієві включення, б) – паперові включення

Навчальний зразок №2 має внутрішню структуру та схему розташування штучних дефектів, аналогічні до зразка №1. Відмінністю є те, що навчальний зразок №2 містить дефекти лише у вигляді повітряних порожнин. На рис. 4.18 показані приклади диференціальних температурних сигналів від штучних дефектів зразка №2, які мають різну глибину залягання. Відповідні їм температурні профілі були використані для формування навчальної множини. Приклади термограм навчальних зразків №1 та №2 наведено в Додатку А.




Рис. 4.18. Диференціальні температурні сигнали від дефектів навчального зразка №6 на різних глибинах залягання

В результаті контролю навчальних зразків, сформовано множину векторів загальним обсягом 6545 навчальних пар. До даної множини включено 3605 прикладів температурних профілів бездефектних ділянок, 1414 профілів дефектів у вигляді повітряних порожнин, 1019 профілів дефектів у вигляді паперових включень та 507 профілів дефектів у вигляді алюмінієвих включень. Навчальна вибірка характеризується певною нерівномірністю, яка виникла через обмежену кількість навчальних зразків. Множина навчальних векторів була розділена на навчальну / тестову / валідаційну підмножини у пропорції 70 % / 15 % / 15 % відповідно.

4.1.5. Обробка експериментальних даних із використанням розробленої нейромережевої системи

З метою обробки експериментальної послідовності термограм зразка №7 з використанням розробленої системи аналізу результатів активного теплового

контролю, було створено та навчено НМ відповідних модулів виявлення та класифікації, визначення глибини залягання та розкриття дефектів. Початково було обрано архітектуру НМ з двома прихованими прошарками з кількістю нейронів в першому прихованому прошарку $Np_1 = 12$ та в другому прихованому прошарку $Np_2 = 4$. Саме така архітектура була визначена найбільш оптимальною за результатами комп'ютерного моделювання. Однак, в задачах обробки реальних експериментальних даних мережі зазначеної архітектури продемонстрували низькі результати. Тому для вибору архітектури мереж нейромережевих модулів було проведено додаткове дослідження.

Для кожного нейромережевого модуля було навчено по п'ять НМ різної архітектури, з яких обрано найкращі за показником середньоквадратичної помилки мережі. Результати навчання НМ різних архітектур для обробки послідовностей термограм зразка №3 наведено в таблиці 4.1.

Таблиця 4.1. Ефективність навчених НМ в залежності від архітектури (зразок №3)

Критерій	$Np_1 = 12$ $Np_2 = 4$	$Np_1 = 24$ $Np_2 = 8$	$Np_1 = 30$ $Np_2 = 12$	$Np_1 = 35$ $Np_2 = 15$	$Np_1 = 40$ $Np_2 = 18$
Час навчання мережі класифікації, хв	17	21	28	31	45
Кількість епох навчання мережі класифікації	156	138	141	121	172
MSE мережі класифікації	0,0754	0,0059	0,0049	0,0022	0,0023
Час навчання мережі визначення глибини, хв	9	14	14	18	27
Кількість епох навчання мережі визначення глибини	187	239	214	247	285
MSE мережі визначення глибини	0,1120	0,0893	0,0731	0,0590	0,0587
Час навчання мережі визначення розкриття, хв	7	13	18	19	31
Кількість епох навчання мережі визначення глибини	183	231	209	262	306
MSE мережі визначення розкриття	0,0873	0,0630	0,0236	0,0124	0,0131

На основі даних таблиці 4.1 можна зробити висновок, що найбільш оптимальною архітектурою НМ для обробки послідовностей термограм обох тестових зразків є $Np_1 = 35$ та $Np_2 = 15$. Ускладнена архітектура не демонструє помітного покращення результатів, але призводить до збільшення часу навчання. Використання менш складної архітектури призводить до збільшення помилки мережі. Отже, для вирішення поставлених задач доцільно обрати архітектуру нейромереж виявлення та класифікації дефектів, показану на рис. 4.19. Архітектура мереж визначення глибини залягання та розкриву дефектів є аналогічною.

Вхідний прошарок містить 20 нейронів, що відповідає кількості термограм у послідовності. Вихідний прошарок містить 4 (у відповідності до кількості класів) або 1 нейрон. Для навчання використовувались параметри, навчальна функція та обладнання, описані в п. 3.2.4.




Рис. 4.19. Архітектура НМ виявлення та класифікації дефектів зразка №7

Для кожного нейромережевого модуля навчено по 5 НМ, з яких обрано найкращу. Приклад зміни середньоквадратичної помилки під час навчання мережі виявлення та класифікації дефектів показано на рис. 4.20. Аналогічні графіки для мереж визначення глибини залягання та розкриву дефектів наведені в Додатку Б. В таблиці 4.2 наведено результати навчання всіх нейромережевих модулів.

Карта дефектів, побудована за результатами роботи нейромережевого модуля виявлення та класифікації дефектів, показана на рис. 4.21, а. На карті виявлено та безпомилково класифіковано всі 12 штучних дефектів. Форма та розміри дефектів є близькими до істинних. На зображенні можна помітити точкові відмітки хибно класифікованих температурних профілів, які можуть відфільтровані за допомогою медіанного фільтру.




Рис. 4.20. Зміна MSE під час навчання мережі виявлення та класифікації дефектів зразка №3

Таблиця 4.2. Результати навчання НМ для обробки експериментальних даних (зразок №3)

Задача мережі \ параметр	Час навчання, хв	Кількість епох	MSE
Класифікація дефектів	48	200	0,006
Визначення глибини	80	360	0,083
Визначення розкриву	108	445	0,037

На рис. 4.21, б показано теплову томограму внутрішньої структури зразка №3, яка була побудована на основі результатів роботи нейромережових модулів визначення глибини залягання та розкриву дефектів. На границях дефектів присутні негативні крайові ефекти у вигляді аномальних викидів. Даний ефект може бути скоригованим у випадку використання медіанної фільтрації. В цілому, зображення внутрішньої структури є достовірним, глибини залягання та розкрив дефектів визначено з високою точністю. Кількісна оцінка визначених параметрів та порівняння результатів із традиційними методами наводиться в таблиці 4.3.

На рис. 4.22 показано передню панель ВП розробленої автоматизованої системи під час аналізу результатів контролю зразка №3. Результати свідчать про перевагу нейромережової системи над традиційними методами на якісному рівні. Важливою особливістю є висока завадостійкість розробленої системи, оскільки показані результати отримано в умовах значної нерівномірності нагріву.

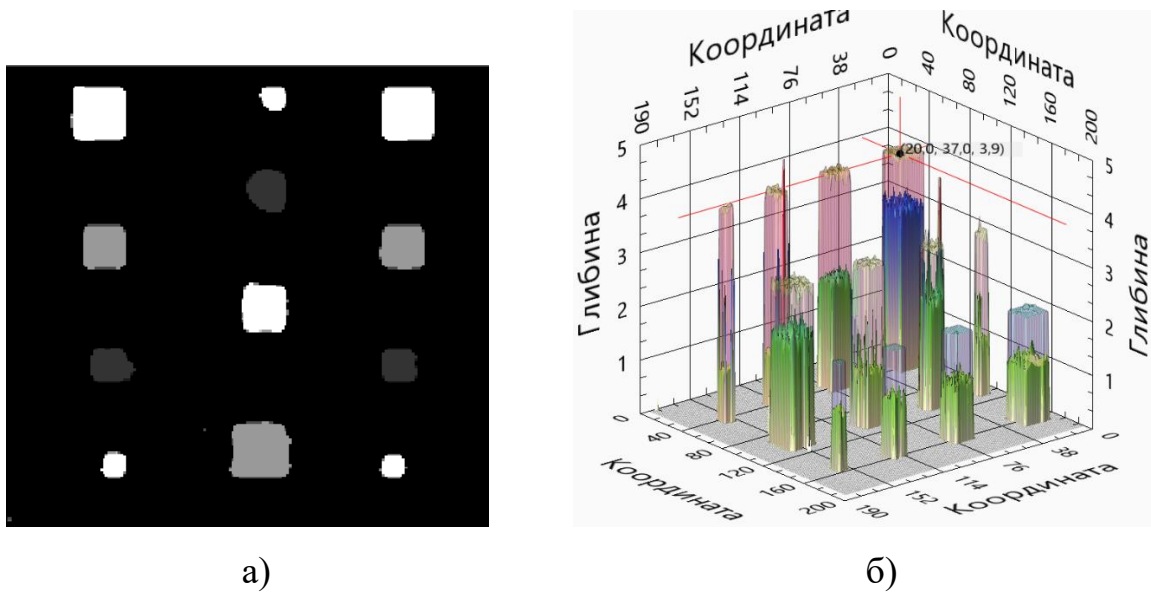


Рис. 4.21. Результати обробки експериментальних даних неймережевими модулями: а) – карта дефектів, б) – внутрішня структура ОК

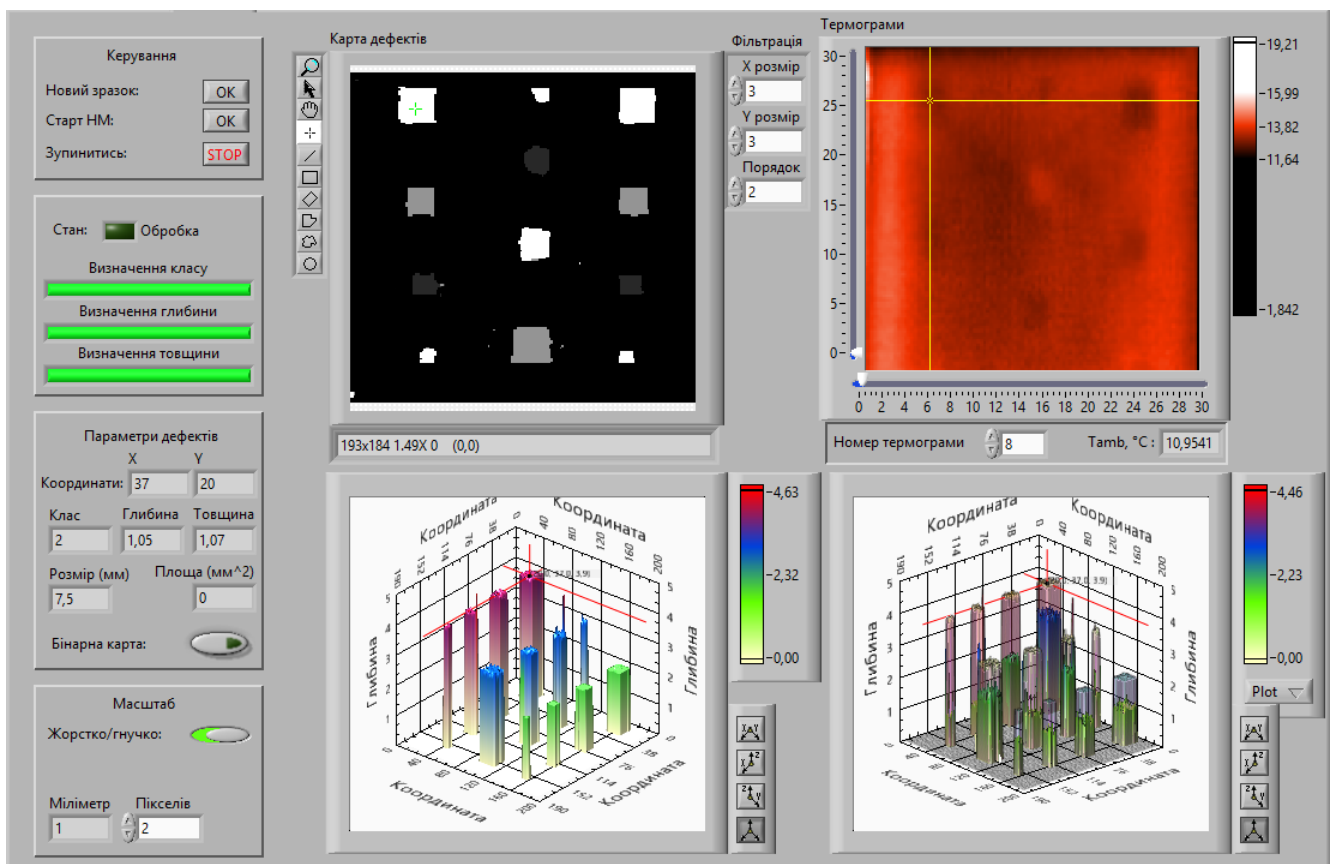


Рис. 4.22. Передня панель розробленої системи під час обробки експериментальних даних контролю зразка №3

4.1.6. Аналіз та оцінка результатів експерименту

За результатами кількісної оцінки ефективності виявлення дефектів зразка №3 різними методами (таблиця 4.3) встановлено, що найкращі результати демонструє розроблена система аналізу даних теплового контролю із використанням удосконаленого методу визначення характеристик дефектів. Зокрема, використання НМ є єдиним методом, завдяки якому вдалося виявити всі 12 штучних дефектів зразка №3 та автоматично безпомилково класифікувати їх за типом.

Нейромережевий модуль виявлення та класифікації дефектів дозволяє визначити розміри дефектів за їх тепловими відбитками з найвищою серед розглянутих методів точністю. Температурні профілі були автоматично класифіковані з помилкою 15,69 %. Значення критерію Танімото на рівні 88,08 % підтверджує високу достовірність побудованої карти дефектів.

Найбільш ефективним після НМ методом виявлення дефектів є МАГК. Обробка експериментальної послідовності термограм даним методом дозволяє виявити 11 штучних дефектів зразка №3 та оцінити їх розміри. Побудована бінарна карта внаслідок високого рівня завад має низьку достовірність за критерієм Танімото (23,63 %). Інші методи обробки термограм продемонстрували помітно гірші результати. Особливо низьку ефективність мають методи, які потребують використання опорної точки.

В розглянутих умовах контролю використання НМ є єдиним методом, що дає можливість ефективно визначити глибину залягання дефектів. Відповідний нейромережевий модуль дозволяє визначити глибину штучних дефектів зразка №3 з граничною відносною похибкою $\pm 4,74\%$. Метод ДТТ в аналогічній задачі продемонстрував негативні результати, що унеможлиблює оцінку точності визначення глибини залягання та побудови теплової томограми.

Гранична відносна похибка визначення розкриття дефектів нейромережевим модулем складає $\pm 2,89\%$. Побудована тепла томограма внутрішньої структури зразка №3 в цілому є достовірною, однак на границях деяких дефектів

спостерігаються негативні крайові ефекти. У зв'язку з цим, вимірювання розкриву проводилось в центральних точках теплових відбитків дефектів.

Таблиця 4.3. Кількісна оцінка результатів обробки експериментальної послідовності термограм зразка №3 різними методами

Критерій\метод	Опт. термограма	Фур'є-аналіз	Вейвл. аналіз	МАГК	ДТТ	НМ
Кількість виявлених дефектів	8	10	7	11	8	12
Помилка класифікації температурних профілів, %	–	–	–	–	–	15,69
Критерій Танімото, %	19,48	10,97	6,38	23,62	7,03	88,08
Середньоквадратична похибка визначення глибини, мм	–	–	–	–	–	±0,11
Гранична відносна похибка визначення глибини, %	–	–	–	–	–	±3,19
Середньоквадратична похибка визначення розкриву, мм	–	–	–	–	–	±0,05
Гранична відносна похибка визначення розкриву, %	–	–	–	–	–	±3,50

Отже, використання НМ для обробки експериментальної послідовності термограм тестового зразка №3 демонструє переваги нейромережових модулів над традиційними методами в усіх задачах контролю та дефектометрії. Завдяки високій завадостійкості та узагальнюючим властивостям НМ, наявність нерівномірності нагріву слабо впливає на ефективність виявлення дефектів та точність вимірювання їх параметрів.

4.2. Рекомендації щодо проведення контролю із використанням розробленої системи аналізу даних

Розроблена автоматизована система обробки даних теплового контролю із використанням удосконаленого методу визначення характеристик дефектів завдяки високому рівню адаптивності та універсальності може бути використана

для контролю та дефектометрії широкого спектру виробів. На даний час система оптимізована для задач контролю виробів із багат шарових та композиційних матеріалів товщиною до 10 мм. Ефективність роботи системи продемонстрована на якісному та кількісному рівнях для контролю зразків із багат шарового АБС-пластику, текстоліту та склотекстоліту. Основними типами внутрішніх дефектів, які рекомендується виявляти та аналізувати за допомогою розробленої системи, є повітряні порожнини, розшарування, непроклеї, обриви армуючих елементів КМ, включення сторонніх матеріалів.

Контроль рекомендується проводити на етапі виробництва в лабораторних умовах. Для підвищення результативності, в приміщенні має бути мінімізований вплив сторонніх джерел нагріву та руху повітря на ОК. Однак, нейромереві алгоритми роботи системи потенційно дозволяють використовувати її і для контролю виробів на етапі експлуатації. В такому випадку, може знадобитися більш широка номенклатура навчальних зразків. Дослідження ефективності роботи системи у випадку контролю об'єктів під час експлуатації наразі не проводились. Рекомендується виконувати контроль однорідних виробів, що потребуватиме лише однократного навчання нейромеревих модулів.

Гнучкість та універсальність алгоритмів автоматизованої системи дозволяють проводити активний ТНК як за односторонньою, так і за двосторонньою схемою. За можливості, рекомендується використання схеми контролю з двостороннім доступом до ОК з метою більш ефективного забезпечення рівномірності нагріву. У випадку зміни схеми контролю має проводитись відповідне перенавчання нейромеревих модулів.

Обов'язковими апаратними засобами для здійснення НК із використанням розробленої системи є безконтактне джерело нагріву потужністю від 600 Вт та тепловізор з можливістю експорту записаних термограм на ПК або ноутбук. Рекомендується використання імпульсних джерел нагріву високої потужності (тривалість імпульсу нагріву до 1 с, густина потужності теплового потоку від 1 кВт/м²). Для забезпечення розглянутих характеристик точності до тепловізійного обладнання висуваються наступні вимоги:

- можливість автоматичного або ручного запису послідовності термограм з кадровою частотою не менше 10 знімків/хв;
- температурна чутливість не менше 80 мК;
- роздільна здатність записаних термограм не менше 320 x 240 пікселів;
- можливість збереження отриманих термограм у форматі матриць піксельних температур;
- похибка вимірювання температури не більше $\pm 2\%$.

Стенд для проведення контролю має забезпечувати жорстку фіксацію положення джерела нагріву, ОК та тепловізора протягом повного процесу запису послідовності термограм. ОК має бути розташовано в центральній частині основного теплового потоку нагріву. Переміщення складових схеми під час контролю може призвести до отримання недостовірних теплових профілів. У випадку використання двосторонньої схеми контролю, передбачити мінімізацію впливу джерела нагріву на тепловізійне обладнання. З цією метою рекомендується використання захисних пластин з отвором для фіксації малогабаритних ОК.

Підготовка до проведення контролю включає наступні етапи:

1. Обирається схема контролю: з одностороннім або двостороннім доступом до ОК.
2. Зовнішня поверхня ОК механічно очищується від бруду та інших сторонніх потенційних джерел завад;
3. На штатну позицію встановлюється джерело нагріву.
4. На фіксованій відстані від нагрівача (100 – 150 мм) на штатну позицію встановлюється ОК. Розташування ОК має бути таким, щоб на нього рівномірно припадала основна частина теплового випромінювання джерела нагріву. У випадку двосторонньої схеми контролю, головна площа ОК має бути розташована по нормалі до напрямку поширення теплового випромінювання.
5. На фіксованій відстані від ОК (400 – 500 мм) на штатну позицію встановлюється тепловізійне обладнання. ОК має максимально знаходитись в полі

зору тепловізора. Положення тепловізора жорстко фіксується за допомогою триноги або інших засобів.

6. Тепловізор вмикається та проводяться необхідні попередні налаштування.

7. Відводиться деякий час для вирівнювання температури ОК з температурою навколишнього середовища з метою уникнення впливу теплових відбитків на поверхні ОК, які могли з'явитися під час його встановлення на штатну позицію. Вирівнювання теплового поля ОК контролюється за зображенням на екрані тепловізора.

8. Оператор займає робоче місце у відповідності до покладених задач.

Контроль здійснюється в наступному порядку:

1. За допомогою тепловізора реєструється термограма ОК в початковий момент часу.

2. У випадку використання інерційного джерела нагріву:

2.1. Між джерелом нагріву та ОК встановлюється захисна пластина з матеріалу низької теплопровідності.

2.2. Джерело нагріву вмикається та виводиться на робочу потужність.

2.3. Захисна пластина між ОК та нагрівачем прибирається.

3. Проводиться запис послідовності термограм ОК з певною кадровою частотою. В залежності від потреб, запис може проводитись лише під час нагріву ОК (яке правило, для інерційних нагрівачів) або включати також запис стадії охолодження ОК (переважно у випадку використання імпульсних джерел нагріву).

4. У момент, коли тривалість контролю починає значно перевищувати оптимальний час контролю, запис термограм зупиняється.

5. Якщо запис термограм проводився лише на стадії нагріву, та у момент завершення реєстрації послідовності термограм нагрівач є активним, нагрівач вимикається.

6. ОК охолоджується до безпечної температури ($<40\text{ }^{\circ}\text{C}$) та прибирається зі штатної позиції.

7. Записані термограми експортуються на ПК для подальшої обробки.

8. Записана послідовність термограм зберігається у вигляді масиву піксельних значень температур та імпортується до розробленої автоматизованої системи аналізу даних.

9. На передній панелі ВП розробленої системи виконуються попередні налаштування.

10. Після налаштування системи, розроблений ВП запускається. На передній панелі ВП натискається кнопка «Новий зразок».

11. Після завершення роботи нейромережових модулів, оператором здійснюється аналіз та оцінка отриманих результатів. Вимірювання глибини залягання та розкриття дефектів рекомендується проводити в центрах мас відповідних теплових відбитків дефектів.

12. За результатами контролю складається відповідний звіт.

Описані вище рекомендації щодо методики контролю сформовані на основі результатів, отриманих під час проведення експериментальних досліджень ефективності роботи розробленої системи багатопараметрового активного теплового контролю. Окремі дії можуть відрізнитись від описаних в залежності від конкретної задачі контролю, обраної схеми контролю, характеристик ОК та обладнання. У разі зміни типу ОК, нагрівача або тепловізора, може знадобитись перенавчання нейромережових модулів системи або їх донавчання за допомогою функцій адаптації синаптичних ваг.

Висновки до розділу 4

1. Проведено експериментальні дослідження ефективності розробленої автоматизованої системи аналізу даних теплового контролю із використанням удосконаленого методу визначення характеристик дефектів. Розроблено та виготовлено дослідні зразки з багатошарового склотекстоліту. Обґрунтовано та розроблено експериментальну установку для проведення активного ТНК за схемою з двостороннім доступом до ОК.

2. На основі експериментальних даних визначено, що в реальних умовах контролю оптимальною є архітектура НМ, яка містить 35 нейронів в першому

прихованому прошарку та 15 нейронів в другому прихованому прошарку. Доведено, що наявність нерівномірності нагріву або інших завад призводить до необхідності ускладнення архітектури нейромережових модулів.

3. За результатами експериментальних досліджень встановлено, що:

– найкращі результати в задачах виявлення та класифікації дефектів має розроблена автоматизована система. Використання НМ є єдиним методом, який дозволяє виявити та безпомилково класифікувати всі штучні дефекти, які закладені в тестові зразки.

– значення критерію Танімото для отриманих за допомогою розробленої системи карт дефектів складає 88,08 %. Найближче значення за даним показником має МАГК ($T = 23,62$ %). Незадовільний рівень критерію Танімото для традиційних методів пояснюється їх низькою завадостійкістю та особливими вимогами до обладнання, яке використовується під час контролю.

– гранична відносна похибка визначення глибини залягання дефектів за допомогою розробленої системи складає $\pm 3,19$ %, що свідчить про підвищення точності у порівнянні з класичним методом ДТТ.

– в задачі визначення розкриву, гранична відносна похибка відповідного нейромережевого модуля складає до $\pm 3,50$ %.

4. Доведено високу завадостійкість НМ та їх здатність ефективно працювати в умовах нерівномірності нагріву або недостатньої кількості навчальних зразків. Встановлено, що найгіршим методом оброки експериментальних послідовностей термограм в розглянутих умовах контролю у метод вейвлет-аналізу, який дає негативні результати для всіх трьох тестових зразків.

5. На основі проведених експериментів розроблено загальні рекомендації щодо проведення контролю із використанням розробленої автоматизованої системи. На даному етапі рекомендується використання системи в лабораторних умовах для контролю однотипних об'єктів.

ВИСНОВКИ

У дисертаційній роботі вирішена актуальна науково-прикладна задача наукового обґрунтування та розробки аналізу даних теплового контролю із використанням удосконаленого методу визначення характеристик дефектів.

1. Аналіз традиційних методів активного теплового контролю виробів із багат шарових матеріалів показав, що існуючі рішення мають ряд недоліків у вигляді низької завадостійкості, залежності результатів від вибору опорної точки, параметрів джерела нагріву та тепловізійного обладнання, низької адаптивності та інформативності. За певних умов, існуючі методи дозволяють підвищити візуальну якість отриманих термограм, покращити співвідношення сигнал/шум. Однак, для забезпечення прийнятної точності визначення глибини залягання дефектів за допомогою традиційних методів, висуваються високі вимоги до характеристик обладнання та умов проведення контролю. Окрім того, розглянуті методи не дозволяли проводити оцінку розкриву дефектів.

2. Обґрунтовано можливість удосконалення методу оцінки характеристик дефектів багат шарових матеріалів при активному тепловому контролі. Встановлено переваги нейронних мереж перед традиційними методами обробки послідовностей термограм у вигляді високих узагальнюючих властивостей, високої завадостійкості, універсальності та адаптивності алгоритмів. Це дало змогу підвищити достовірність та інформативність контролю, зменшити роль оператора у прийнятті рішень та підвищити загальну ефективність.

3. Розроблено загальну структуру автоматизованої системи активного теплового контролю, яка містить в своєму складі нейромережевий модуль виявлення та класифікації дефектів, модулі визначення глибини залягання та розкриву дефектів на базі нейронних мереж. Обґрунтовано тип та обрано архітектуру нейронних мереж у вигляді багат шарових мереж прямого розповсюдження зі зворотним поширенням помилки. Реалізовано алгоритми роботи обраних нейронних мереж у складі відповідних нейромережевих модулів.

Це дозволило автоматизувати процеси класифікації дефектів, визначення їх характеристик та побудови теплових томограм

4. Розроблено віртуальні прилади для реалізації роботи та пост-обробки відповідей нейромережевих модулів. На передній панелі віртуального приладу створено графічний інтерфейс користувача для керування системою та обробки отриманих результатів контролю із використанням удосконаленого методу визначення характеристик дефектів. Інтерфейс користувача містить зображення термограм об'єкту контролю та отриманих карт дефектів, а також тривимірну теплову томограму за глибиною залягання дефектів та зображення внутрішньої структури об'єкту контролю. Передня панель віртуального приладу також містить інструменти для вимірювання розмірів та оцінки параметрів дефектів, що дозволило спростити обробку та аналіз даних.

5. Проведено комп'ютерне моделювання процесу активного теплового контролю зразка із багатошарового вуглепластику, що містив моделі штучних дефектів різного типу з різними параметрами. На основі порівняльного аналізу встановлено, що розроблена автоматизована система на базі нейромережевих технологій демонструє перевагу за кількісними та якісними показниками у порівнянні з традиційними методами обробки послідовностей термограм. За результатами моделювання, розроблена система дозволяє виявити та безпомилково класифікувати всі закладені в тестовий зразок штучні дефекти, оцінити їх глибину залягання з відносною похибкою $\pm 7,97\%$ та розкрити з відносною похибкою $\pm 2,41\%$. Значення критерію Танімото на рівні $89,48\%$ для розробленої системи є найвищим серед розглянутих методів обробки термограм, що дозволило підвищити інформативність контролю.

6. В результаті дослідження впливу архітектури нейронних мереж на результати роботи нейромережевих модулів встановлено, що найбільш доцільним є використання двох прихованих прошарків. У разі обробки даних комп'ютерного моделювання, кількісні показники ефективності нейронних мереж помітно не покращуються у випадку ускладнення архітектури вище 12 нейронів в першому прихованому прошарку та 4 нейронів в другому прихованому прошарку.

7. Встановлено, що найкращим алгоритмом навчання нейронних мереж за показником середньоквадратичної помилки мережі є алгоритм оптимізації за методом Левенберга-Маркарда. Однак, інші навчальні алгоритми мають помітно більш високу швидкодію, тому можуть бути використані у випадку невисоких вимог до точності отриманих результатів.

8. Встановлено, що зменшення обсягу навчальної вибірки дозволяє значно скоротити час навчання нейронних мереж відповідних модулів, однак призводить до погіршення точності визначення параметрів дефектів. Визначено, що зменшення кількості навчальних пар в чотири рази дозволяє скоротити час навчання в аналогічну кількість разів. Однак, внаслідок цього на 7,55 % погіршується значення критерію Танімото та на 14,74 % зростає відносна похибка визначення глибини залягання дефектів. Подібні результати отримано і для випадку погіршення репрезентативності вибірки, тому під час формування навчальної множини рекомендується використовувати зразки сигналів від всіх штучних дефектів, які закладені в навчальний зразок.

9. Проведено експериментальні дослідження ефективності роботи розробленої автоматизованої системи із використанням удосконаленого методу визначення характеристик дефектів на фізичних зразках. Для проведення експериментів було розроблено та виготовлено дослідні зразки з багатошарового склотекстоліту. Обґрунтовано використання схеми активного теплового контролю з двостороннім доступом до об'єкту контролю та розроблено відповідний експериментальний стенд. За результатами експериментальних досліджень:

– встановлено, що в умовах обмежених характеристик джерела нагріву та тепловізійного обладнання, а також у випадку наявності нерівномірності нагріву або інших завад, архітектура нейронних мереж має бути ускладнена до значення у 35 нейронів в першому прихованому прошарку та 15 нейронів в другому прихованому прошарку;

– визначено, що в залежності від типу об'єкту контролю та умов проведення експерименту, розроблена автоматизована система дозволяє виявити та

безпомилково класифікувати всі закладені в тестовий зразок штучні дефекти, оцінити їх розміри, глибину залягання з максимальною похибкою $\pm 3,19\%$ та розкрив з похибкою до $\pm 3,50\%$;

– встановлено, що карти дефектів, побудовані в результаті обробки експериментальних послідовностей термограм за допомогою удосконаленого методу на основі нейромережових технологій, мають високу достовірність за критерієм Танімото, значення якого знаходиться на рівні від $88,08\%$.

– за результатами порівняльного аналізу доведено, що розроблена система має перевагу над традиційними методами за якісними та кількісними показниками.

10. На основі результатів експериментальних досліджень, сформовано рекомендації щодо мінімальних характеристик обладнання, яке має застосовуватись для забезпечення розглянутих характеристик ефективності роботи системи. Зміна типу об'єкту контролю, характеристик нагріву або тепловізійного обладнання вимагатиме перенавчання нейромережових модулів, тому рекомендується проводити контроль однотипних зразків в лабораторних умовах.

11. Основним напрямом для подальших досліджень є оптимізація архітектури нейронних мереж відповідних модулів системи із використанням останніх досягнень в області глибинного навчання. Зокрема, пропонується ввести до архітектури мереж прошарки нормалізації та дропауту, змінити навчальний алгоритм оптимізації та активаційну функцію повнозв'язних прошарків. Важливим завданням також є формування широкої бази навчальних зразків з різною конфігурацією. Це дозволить розширити області застосування розробленої автоматизованої системи без необхідності у перенавчанні нейронних мереж для кожної окремої задачі.

12. Результати досліджень впроваджено в навчальний процес кафедри приладів і систем неруйнівного контролю Національного технічного університету України «Київський політехнічний інститут імені Ігоря Сікорського».

СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ

- [1] В. В. Мурашов и А. Ф. Румянцев, «Дефекты монолитных деталей и многослойных конструкций из полимерных композиционных материалов и методы их выявления,» *Контроль. Диагностика*, № 4, pp. 23-32, 2007.
- [2] З. Т. Назарчук, В. В. Кошовий, В. Р. Скальський, О. П. Бухало та Р. Воробець, *Механіка руйнування і міцність матеріалів: Довід. посіб.*, т. 5, Л.: НАН України. Фіз.-мех. ін-т ім. Г. В. Карпенка, 2001, 1134 с.
- [3] I. G. Scott and C. M. Scala, "A review of nondestructive testing of composite materials," *NDT International*, no. 2, pp. 75-86, 1982.
- [4] В. Д. Байда, А. И. Цехан и П. А. Гнаткович, «Неразрушающий контроль отслоений покрытий из композиционных материалов,» *Техническая диагностика и неразрушающий контроль*, № 2, pp. 86-89, 1990.
- [5] R. A. Smith, "Composite defects and their detection," *Mater. Sci. Eng.*, no. 3, pp. 103-143, 2009.
- [6] А. С. Момот та Р. М. Галаган, «Тепловізійний контроль електрообладнання із застосуванням штучних нейронних мереж,» в *Збірник тез доповідей 4-тої науково-практичної конференції студентів і молодих учених «Методи та засоби неруйнівного контролю промислового обладнання»*, Івано-Франківськ, 2013.
- [7] J. G. Sun, "Analysis of pulsed thermography methods for defect depth prediction," *J. Heat Transf.*, vol. 4, no. 128, pp. 329-338, 2006.
- [8] А. В. Переїденко та Є. Ф. Суслов, «Разработка системы неразрушающего контроля композиционных материалов,» в *“PT-2009”: матеріали 5-ї міжнар. молодіжної наук.-техн. конф., 20-25 квітня 2009 р.*, Севастополь, 2009.

- [9] Ю. В. Ланге, *Акустические низкочастотные методы и средства неразрушающего контроля многослойных конструкций*, Москва: Машиностроение, 1991, 272 с.
- [10] В. В. Мурашов, «Акустические методы и средства контроля изделий из композиционных материалов,» *Дефектоскопия*, № 9, pp. 46-51, 1990.
- [11] А. В. Перееденко, Ю. В. Куц и В. С. Еременко, «Применение нейронных сетей для повышения достоверности неразрушающего контроля изделий из композиционных материалов,» *Научни известия*, № 2(139), pp. 62-67, 2013.
- [12] Ю. В. Ланге, «Низкочастотные акустические методы и средства дефектоскопии,» *Приборы и системы управления*, № 5, pp. 4-6, 1989.
- [13] О. Н. Буданин и А. А. Кульков, «Современное состояние методик и аппаратуры неразрушающего контроля изделий из полимерных композиционных материалов,» в *«Современные методы и средства неразрушающего контроля и технической диагностики»: матеріали 21-ї міжнар. конф., 7-11 жовтня 2013 р.*, Гурзуф, 2013.
- [14] І. П. Білокур, *Основи дефектоскопії: Підручник*, Київ: „Азимут-Україна”, 2004, 496 с.
- [15] А. И. Потапов, *Контроль качества и прогнозирование надежности конструкций из композиционных материалов*, СПб: Машиностроение, 1980, 261 с.
- [16] В. П. Малайчук и А. В. Мозговой, *Математическая дефектоскопия: монография*, Днепропетровск: Системные технологии, 2005, 180 с.
- [17] А. С. Момот и Р. М. Галаган, «Статистический анализ взаимосвязей между информативными параметрами активного теплового неразрушающего контроля,» в *Приборостроение-2018: материалы 11-й Международной научно-технической конференции, 14-16 ноября 2018 года, Минск, Республика Беларусь*, Минск, 2018.

- [18] В. П. Вавилов, Инфракрасная термография и тепловой контроль, Москва: ИД Спектр, 2013, 544 с.
- [19] В. В. Ключев, Неразрушающий контроль. Том 5. Книга 1. Тепловой контроль, т. 5, Москва: Машиностроение, 2006, 688 с.
- [20] X. Maldague, F. Galmiche and A. Ziadi, "Advances in pulsed phase thermography," *Infrared Physics & Technology*, no. 43, pp. 175-181, 2002.
- [21] А. С. Момот и Р. М. Галаган, «Использование искусственных нейронных сетей для обработки термограмм,» в *Материалы 7-й Международной студенческой научно-технической конференции «Новые направления развития приборостроения»*, Минск, 2014.
- [22] A. S. Momot and R. M. Galagan, "Statistical analysis of thermal nondestructive testing data," *Advanced Information Systems*, no. 3, pp. 58-62, 2019.
- [23] В. П. Вавилов, Тепловые методы контроля композиционных материалов и изделий радиотехники, Москва, 1984, 287 с.
- [24] Д. А. Рапопорт и О. Н. Дадин, «Модель автоматизированного теплового контроля.,» *Дефектоскопия*, № 12, pp. 65-72, 1983.
- [25] Г. И. Марчук и В. И. Агошков, Введение в проекционно-сеточные методы, Москва: Наука, 2008, 416 с.
- [26] О. М. Алифанов, Е. Л. Артюхин и С. В. Румянцев, Экспериментальные методы решения некорректных задач, Москва: Наука, 1988, 286 с.
- [27] В. П. Малайчук и А. В. Мозговой, Математическая дефектоскопия, Днепропетровск: Системные технологии, 2005, 180 с.
- [28] А. А. Николаев, «Метод распознавания трёхмерных дефектов типа трещин и расслоений в конструкциях,» в *18-я Междунар. конф. по компьютерной графике и зрению "ГрафикКон 2008": тр.конф.*, Москва, 2008.
- [29] Л. Д. Ландау и Е. М. Лифшиц, Теория упругости, Москва: Наука, 1987, 248 с.

- [30] V. P. Vavilov, A. V. Plesovskikh and A. O. Chulkov, "A complex approach to the development of the method and equipment for thermal nondestructive testing of CFRP cylindrical parts," *Composites Part B*, no. 68, pp. 375-384, 2015.
- [31] З. Т. Назарчук, «Теорія, методи та засоби неруйнівного контролю конструкційних матеріалів,» *Відбір і оброб. інформації: міжвід. зб. наук. пр.*, № 15, pp. 37-50, 2001.
- [32] О. Н. Буданин, А. И. Потапов и В. И. Колганов, *Тепловой неразрушающий контроль изделий*, Москва: Наука, 2001, 476 с.
- [33] А. Н. Пичугин, О. Н. Буданин и Ю. В. Антипов, «Исследование возможности диагностики качества сложных пространственных конструкций из полимерных композиционных материалов в процессе их силового нагружения по анализу динамических тепловых полей,» в *Материалы 20-й Юбилейн. междунар. конф. "Современные методы и средства неразрушающего контроля и технической диагностики"*, 1 - 5 окт. 2012 г., Гурзуф, 2012.
- [34] J. Sun, «Analysis of data processing methods for pulsed thermal imaging characterization of delaminations,» *Quant. InfraRed Thermogr. J.*, № 10, pp. 9-25, 2013.
- [35] A. S. Momot, «Thermal defectometry of composite materials using artificial neural networks,» в *XVIII Міжнародна науково-технічна конференція «Приладобудування: стан і перспективи», 15-16 травня 2019 р., м. Київ, Україна: збірник тез доповідей*, Київ, 2019.
- [36] В. П. Вавилов и А. Г. Климов, *Тепловизоры и их применения*, Москва: Интел универсал, 2002, 88 с.
- [37] X. Maldague, *Theory and practice of infrared technology for nondestructive testing*, USA: John Wiley & Sons, 2001, 684 p.
- [38] А. С. Момот та Р. М. Галаган, «Аналіз методів цифрової обробки термограм,» *Вісник Національного технічного університету України*

"Київський політехнічний інститут". Серія приладобудування, № 55, pp. 108-117, 2018.

- [39] J. Peeters, G. Arroud, B. Ribbens, J. J. Dirckx and G. Steenackers, "Updating a finite element model to the real experimental setup by thermographic measurements and adaptive regression optimization," *Mech. Syst. Signal Process.*, no. 64, pp. 428-440, 2015.
- [40] В. П. Вавилов и С. Маринетти, «Импульсная фазовая термография и тепловая томография на базе преобразования Фурье,» *Дефектоскопия*, № 2, pp. 58-72, 1999.
- [41] W. Swiderski, "The characterization of defects in multi-layered composite materials by thermal tomography methods," *ACTA PHYSICA POLONICA A.*, no. 115, pp. 800-804, 2009.
- [42] В. П. Вавилов, А. И. Иванов, Д. А. Нестерук и В. В. Ширяев, «Метод и экспериментальная реализация импульсного теплового контроля плазменных покрытий,» *Известия Томского политехнического университета*, т. 317, № 4, pp. 5-9, 2010.
- [43] В. П. Вавилов, В. В. Ширяев и В. С. Хорев, «Обработка результатов активного теплового контроля методом вейвлет-анализа,» *Дефектоскопия*, № 4, pp. 70-90, 2011.
- [44] В. В. Ширяев, Г. Вэньцзя и Л. Цзинье, «Применение вейвлетов в активном тепловом контроле,» в *VI Научно-практическая конференция «Информационно-измерительная техника и технологии», 27-30 мая 2015, Томск: матер. конф.*, Томск, 2015.
- [45] P. Hlosta, M. Pracht and W. Swiderski, "Processing infrared (IR) images in non-destructive testing of multilayer aramid composite by IR thermography methods," in *12th European Conference on Non-Destructive Testing (ECNDT 2018), Gothenburg 2018, June 11-15 (ECNDT 2018)*, Gothenburg, 2018.

- [46] V. Dattoma, R. Nobile, F. W. Panella and A. Saponaro, "NDT Thermographic Techniques on CFRP Structural Components for Aeronautical Application," *Procedia Struct. Integr.*, no. 8, pp. 452-461, 2018.
- [47] В. П. Вавилов, Д. А. Нестерук и В. В. Ширяев, «Применение Фурье-анализа и метода анализа главных компонент для обработки данных динамического теплового контроля,» *Известия ТПУ*, № 2, pp. 279-285, 2008.
- [48] S. Hermosilla-Lara, P. Joubert and D. Placko, "Enhancement of open-cracks detection using a principal component analysis/wavelet technique in photothermal nondestructive testing," in *Abstr. Intern. Conf. Quant. Infrared Thermography QIRT'02, Dubrovnik, Croatia, Dubrovnik*, 2002.
- [49] В. П. Вавилов, «Динамическая тепловая томография (обзор),» *Заводская лаборатория. Диагностика материалов*, № 3, pp. 26-36, 2006.
- [50] W. Winfree and A. Plotnikov, "Defect Characterization in Composites Using a Thermal Tomography," *Review of Progress in Quantitative Nondestructive Evaluation*, no. 18, pp. 1343-1350, 1999.
- [51] А. С. Момот та Р. М. Галаган, «Реалізація нейромережевих алгоритмів класифікації технічного стану композиційних матеріалів за результатами акустичного контролю,» *Техническая диагностика и неразрушающий контроль*, № 1, pp. 43-46, 2017.
- [52] A. S. Momot and R. M. Galagan, "Analysis of application of neural networks to improve the reliability of active thermal NDT," *KPI Science News*, no. 1, pp. 7-14, 2019.
- [53] С. Хайкин, *Нейронные сети: полный курс, 2-е издание.: Пер. с англ*, Москва: Издательский дом «Вильямс», 2006, 1104 с.
- [54] И. В. Заянцев, *Нейронные сети: основные модели*, Воронеж, 1999, 75 с.
- [55] А. С. Момот та Р. М. Галаган, «Огляд штучних нейронних мереж, що можуть бути застосовані в ультразвуковому неруйнівному контролі,» в *Збірник тез*

доповідей VII н.-п. конференції студентів та аспірантів «Погляд у майбутнє приладобудування», Київ, 2015.

- [56] R. Sun and L. Bookman, Computational Architectures Integrating Neural and Symbolic Processes, Needham, MA: Kluwer Academic Publishers, 1994, 496 p.
- [57] J. A. Freeman and D. M. Skapura, Neural networks. Algorithms, applications, and programming techniques, Massachusetts: Addison-Wesley Publishing Co., 1991, 401 p.
- [58] Я. Гудфеллоу, И. Бенджио и А. Курвилль, Глубокое обучение/ пер. с англ. А.А. Слинкина, 2 ред., Москва: ДМК Пресс, 2018, 652 с.
- [59] Ф. Уоссермен, Нейрокомпьютерная техника, Москва: Мир, 1992, 118 с.
- [60] R. Rosenblatt, Principles of Neurodynamics, New York: Spartan Books, 1962, 157 p.
- [61] А. Н. Горбань, В. Л. Дунин-Барковский и А. Н. Кирдин, Нейроинформатика, Новосибирск: Наука. Сибирское предприятие РАН, 1998, 296 с.
- [62] А. И. Галушкин, Нейронные сети: основы теории, Москва: Горячая линия – Телеком, 2010, 480 с.
- [63] А. Н. Горбань и Д. А. Россиев, Нейронные сети на персональном компьютере, Новосибирск: Наука, 1996, 270 с.
- [64] А. Б. Барский, Нейронные сети: распознавание, управление, принятие решений, Москва: Финансы и статистика, 2004, 176 с.
- [65] I. Goodfellow, Y. Bengio and A. Courville, Deep Learning (Adaptive Computation and Machine Learning series), Cambridge, Massachusetts: The MIT Press, 2016, 800 p.
- [66] С. Николенко, А. Кадури и Е. Архангельская, Глубокое обучение. Погружение в мир нейронных сетей, СПб.: Питер, 2017, 480 с.
- [67] T. Kohonen, Self Organization and Associative Memory, New York: Springer-Verlag, 1989, 147 p.

- [68] S. Sojasi, "Infrared Testing of CFRP Components: Comparisons of Approaches using the Tanimoto Criterion," in *NDT in Canada 2015 Conference*, Edmonton, 2015.
- [69] А. Н. Тихонов и В. Я. Арсенин, Методы решения некорректных задач, Москва: Наука, 1986, 288 с.
- [70] А. М. Денисов, «Единственность решения некоторых обратных задач для уравнения теплопроводности с кусочно-постоянным коэффициентом,» *Журн. выч. матем. и матем. физ.*, № 4, pp. 858-864, 1982.
- [71] Д. В. Куш, «О единственности определения кусочно-постоянных коэффициентов уравнения теплопроводности,» *Вестник Моск. ун-та*, № 6, pp. 73-76, 1988.
- [72] А. А. Николаев, «Метод распознавания трехмерных дефектов типа трещин и расслоений в конструкциях,» в *24-я Междунар. конф. по компьютерной графике и зрению "ГрафикКон 2014"*, Москва, 2014.
- [73] А. А. Николева, «Методика вычислительной диагностики трёхмерных дефектов в композитных элементах конструкций на основе теплового неразрушающего контроля,» в *Тезисы доклада 8-й Междунар. конф. "Неразрушающий контроль и техническая диагностика в промышленности"*, Москва, 18-20 марта 2009 г., Москва, 2009.
- [74] V. P. Vavilov, A. O. Chulkov, D. A. Derusova and P. Yangyang, "Thermal NDT research at Tomsk Polytechnic University," *Quantitative InfraRed Thermography Journal*, vol. 2, no. 13, pp. 128-143, 2016.
- [75] V. P. Vavilov and D. A. Nesteruk, "Active thermal inspection of composite materials with the use of neural networks," *Russian Journal of Nondestructive Testing*, no. 2011, pp. 655-662, 2011.
- [76] A. O. Chulkov, D. A. Nesteruk and V. P. Vavilov, "An Automated Algorithm for Constructing Maps of Defects in Active Thermal Testing," *Russian Journal of Nondestructive Testing*, vol. 8, no. 55, pp. 617-621, 2019.

- [77] В. П. Вавилов и Д. А. Нестерук, «Активный тепловой контроль композиционных материалов с использованием нейронных сетей,» *Дефектоскопия*, № 10, pp. 10-18, 2011.
- [78] H. Halloua, A. Elhassnaoui, A. Saifi, A. Obbadi, Y. Errami and S. Sahnoun, "An intelligent method using neural networks for Depth detection by standard thermal contrast in active thermography," in *13th International Conference on Quantitative Infrared Thermography 2016, July 4-8, Gdańsk, Poland (QIRT 2016)*, Gdańsk, 2016.
- [79] N. Saeed, M. A. Omar and Y. Abdulrahman, "A neural network approach for quantifying defects depth, for nondestructive testing thermograms," *Infrared Physics & Technology*, no. 94, pp. 55-64, 2018.
- [80] В. А. Барынин, О. Н. Буданин и А. А. Кульков, *Современные технологии неразрушающего контроля конструкций из полимерных композиционных материалов*, Москва: ИД "СПЕКТР", 2013, 243 с.
- [81] А. В. Переїденко, В. С. Єременко та О. В. Монченко, «Застосування нейромережевих технологій у системах неруйнівного контролю,» *Техническая диагностика и неразрушающий контроль*, № 1, pp. 35-41, 2012.
- [82] З. Г. Салихов, О. Н. Буданин и Е. Н. Ишметьев, *Инженерные основы теплового контроля*, Москва: ИД МИСиС, 2008, 476 с.
- [83] А. С. Момот та Р. М. Галаган, «Застосування нейромережевих технологій для вирішення обернених задач неруйнівного контролю,» в *XVI Міжнародна науково-технічна конференція «Приладобудування: стан і перспективи», 16-17 травня 2017 р., м. Київ, Україна: збір. тез доповідей*, Київ, 2017.
- [84] С. С. Aggarwal, *Neural Networks and Deep Learning*, Springer: Springer International Publishing, 2018.
- [85] L. De Marchi and L. Mitchell, *Hands-On Neural Networks*, Birmingham: Packt Publishing, 2019.

- [86] V. Basili and B. Boehm, "Gaining Intellectual Control of Software Development," *IEEE Computer*, vol. 5, no. 33, pp. 27-33, 2000.
- [87] G. A. Carpenter and S. Grossberg, "A massively parallel architecture for a self-organizing neural pattern recognition machine," *Computer Vision, Graphics, and Image Processing*, no. 37, pp. 54-115, 1987.
- [88] G. A. Carpenter, S. Carpenter and D. B. Rosen, "An adaptive resonance algorithm for rapid category learning and recognition," *Neural Networks*, no. 4, pp. 493-504, 1991.
- [89] А. С. Момот та Р. М. Галаган, «Застосування нейронної мережі АРТ-2 для обробки інформаційних сигналів неруйнівного контролю,» в *Збірник тез доповідей XV Міжнародної науково-технічної конференції "ПРИЛАДОБУДУВАННЯ: стан і перспективи"*, Київ, 2016.
- [90] G. A. Carpenter, S. Grossberg and D. B. Rosen, "Fuzzy ART: Fast stable learning and categorization of analog patterns by an adaptive resonance system," *Neural Networks*, no. 4, pp. 759-771, 1991.
- [91] C. Ibarra-Castanedo, A. Bendada and X. Maldague, "Image and signal processing techniques in pulsed thermography," *GESTS Int. Trans. Comput. Sci. Eng.*, no. 22, pp. 89-100, 2005.
- [92] А. В. Перееденко и В. С. Еременко, «Система неразрушающего контроля композиционных материалов на основе нейронных сетей ART-2 и Fuzzy-ART,» *Техническая диагностика и неразрушающий контроль*, № 1, pp. 28-34, 2013.
- [93] A. S. Momot and R. M. Galagan, "The use of ART-2 neural network for processing information signals of non-destructive testing," in *proc. 2017 IEEE First Ukraine Conference on Electrical and Computer Engineering (UKRCON) Kiev, 29 May-2 June 2017*, Kyiv, 2017.
- [94] T. Rashid, *Make Your Own Neural Network*, Scotts Valley: CreateSpace Independent Publishing Platform, 2016, 222 p.

- [95] J. Loy, *Neural Network Projects with Python*, Birmingham: Packt Publishing, 2019.
- [96] A. M. Shirshova, «Neural networks in active thermal nondestructive testing,» в *«Информационно-измерительная техника и технологии»: материалы III Научно-практической конференции, г. Томск, 3 – 5 мая 2012 г.,* Томск, 2012.
- [97] A. S. Momot and R. M. Galagan, "The Use of Backpropagation Artificial Neural Networks in Thermal Tomography," in *proc. 2018 IEEE First International Conference on System Analysis & Intelligent Computing (SAIC) Kiev, 8-12 October 2018*, Kyiv, 2018.
- [98] N. Buduma and N. Locascio, *Fundamentals of Deep Learning*, Sebastopol: O'Reilly Media, 2017.
- [99] С. А. Айвазян и В. М. Бухштабер, *Прикладная статистика. Классификация и снижение размерности: Справ. изд.,* Москва: Финансы и статистика, 1989, 607 с.
- [100] М. Дорожовець, *Опрацювання результатів вимірювань*, Львів: Львівська політехніка, 2007, 624 с.
- [101] Ю. И. Журавлев, В. В. Рязанов и О. В. Сенько, «Распознавание». Математические методы. Программная система. Практические применения, Москва: Фазис, 2005, 176 с.
- [102] I. H. Witten, E. Frank and M. A. Hall, *Data Mining: Practical Machine Learning Tools and Techniques*, Burlington: Morgan Kaufmann, 2011, 664 p.
- [103] C. M. Bishop, *Neural networks for pattern recognition*, Oxford: Clarendon Press, 1995, 498 p.
- [104] U. Michelucci, *Advanced Applied Deep Learning*, New York: Apress, 2019.
- [105] В. А. Бархатов, «Распознавание дефектов с помощью искусственной нейронной сети специального типа,» *Дефектоскопия*, № 2, pp. 28-39, 2006.
- [106] M. Kubat, *An Introduction to Machine Learning (2nd ed.)*, Berlin: Springer, 2017.

- [107] S. Pareek, R. Sharma and R. Maheshwari, "Application of artificial neural networks to monitor thermal condition of electrical equipment," in *Condition Assessment Techniques in Electrical Systems (CATCON), 2017 3rd International Conference, 16-18 Nov. 2017*, Rupnagar, 2017.
- [108] А. С. Момот та Р. М. Галаган, «Теплова томографія із застосуванням штучних нейронних мереж,» в *XVII Міжнародна науково-технічна конференція «Приладобудування: стан і перспективи», 15-16 травня 2018 р., м. Київ, Україна : збірник тез доповідей*, Київ, 2018.
- [109] S. Jiangang, «Analysis of data processing methods for pulsed thermal imaging characterisation of delaminations,» *Quantitative InfraRed Thermography Journal*, № 10, pp. 9-25, 2013.
- [110] S. Dudzik, «Analysis of the accuracy of a neural algorithm for defect depth estimation using PCA processing from active thermography data,» *Infrared Physics & Technology*, № 56, pp. 1-7, 2013.
- [111] А. Я. Суранов, *LabVIEW 8.20: Справочник по функциям*, Москва: ДМК Пресс, 2007.
- [112] Р. Ш. Загидулин, *LabVIEW в исследованиях и разработках*, Москва: Горячая линия, 2005.
- [113] А. Гилат, *MATLAB. Теория и практика*, Москва: ДМК-Пресс, 2016.
- [114] V. K. Ingle and J. G. Proakis, *Digital Signal Processing using MATLAB*, Stamford: Cengage Learning, 2011.
- [115] В. П. Фудосеев, *Цифровая обработка сигналов в LabVIEW*, Москва: ДМК Пресс, 2007.
- [116] B. Krose and P. Van Der Smagt, *An introduction to neural networks*, 8th ed, Amsterdam: University of Amsterdam, 1996.
- [117] G. Cybenko, "Approximation by superposition of a sigmoidal function," *Mathematics of Control, Signals and Systems*, Vols. 303-314, no. 2, 1989.


- [118] S. L. Ozesmi, C. O. Tanb and U. Ozesmi, "Methodological issues in building, training, and testing artificial neural networks in ecological applications," *Ecological modelling*, no. 195, pp. 83-93, 2006.
- [119] А. С. Момот, «Нейромережева система теплової дефектометрії,» в *II науково-технічна конференція "НК в контексті асоційованого членства України в ЄС" 15-19 жовтня 2018, м. Люблін, Польща, Люблін, 2018.*
- [120] S. Dudzik, "Two-stage neural algorithm for defect detection and characterization uses an active thermography," *Infrared Physics & Technology*, no. 71, pp. 187-197, 2015.
- [121] А. В. Коваленко, А. М. Узденова и М. Х. Утренов, Математическое моделирование физико-химических процессов в среде Comsol Multiphysics 5.2, СПб: Лань, 2017.
- [122] В. А. Прахт, В. А. Дмитриевский и Ф. Н. Сарапулов, Моделирование тепловых и электромагнитных процессов в электротехнических установках. Программа Comsol, Москва: Спутник+, 2011.
- [123] S. Gholizadeh, "A Review of Nondestructive Testing Methods of Composite Materials," *Procedia Struct. Integr*, no. 1, pp. 50-57, 2016.
- [124] N. Rajic, "Principal component thermography for flaw contrast enhancement and flaw depth characterization in composite structures," *Composite Structures*, no. 58, pp. 521-528, 2002.
- [125] N. Saeed, H. Al Zarkani and M. A. Omar, "Sensitivity and Robustness of Neural Networks for Defect-Depth Estimation in CFRP Composites," *Journal of Nondestructive Evaluation* , no. 37, pp. 56-62, 2019.
- [126] А. С. Момот, «Defect classification in active thermal testing with the use of neural networks,» в *Матеріали III науково-технічної конференції «Неруйнівний контроль в контексті асоційованого членства України в Європейському Союзі» з міжнародною участю, Київ, 2019.*

- [127] A. F. Gad, *Practical Computer Vision Applications Using Deep Learning with CNNs*, New York: Apress, 2018.
- [128] J. Krohn, G. Beyleveld and A. Bassens, *Deep Learning Illustrated: A Visual, Interactive Guide to Artificial Intelligence (Addison-Wesley Data & Analytics Series)*, Boston: Addison-Wesley Professional, 2019.
- [129] D. Marquardt, "An Algorithm for Least-Squares Estimation of Nonlinear Parameters," *SIAM Journal on Applied Mathematics*, vol. 2, no. 11, pp. 431-441, 1963.
- [130] J. E. Dennis and R. B. Schnabel, *Numerical Methods for Unconstrained Optimization and Nonlinear Equations*, Englewood Cliffs, NJ: Prentice-Hall, 1983.
- [131] J. MacKay and J. C. David, "Bayesian interpolation," *Neural computation*, vol. 3, no. 4, pp. 415-447, 1992.
- [132] M. T. Hagan, H. B. Demuth and M. H. Beale, *Neural Network Design*, Boston, MA: PWS Publishing, 1996.
- [133] M. Riedmiller and H. Braun, "A direct adaptive method for faster backpropagation learning: The RPROP algorithm," in *Proceedings of the IEEE International Conference on Neural Networks*, 1993.
- [134] А. С. Момот та Р. М. Галаган, «Дослідження ефективності нейронних мереж в активному тепловому контролі в залежності від характеристик навчальної вибірки,» в *9-а Національна науково-технічна конференція і виставка «Неруйнівний контроль та технічна діагностика – UkrNDT-2019»*, Київ, 2019.
- [135] A. Momot and R. Galagan, "Influence of architecture and training dataset parameters on the neural networks efficiency in thermal nondestructive testing," *Sciences of Europe*, vol. 1, no. 44, pp. 20-25, 2019.


- [136] Z. Wang, G. Tian, M. Meo and F. Ciampa, "Image processing based quantitative damage evaluation in composites with long pulse thermography," *NDT&E Int.*, no. 99, pp. 93-104, 2018.
- [137] Ф. Мэттьюз и Р. Ролингс, Композитные материалы. Механика и технология, Москва: Техносфера, 2004.
- [138] Ю. А. Михайлин, Специальные полимерные композиционные материалы, Санкт-Петербург: НОТ, 2009.

ДОДАТОК А


Термограми навчального зразка №1: а) – в початковий момент запису, б) – на половині тривалості нагріву, в) – в кінцевий момент запису



Термограми навчального зразка №2: а) – в початковий момент запису, б) – на половині тривалості нагріву, в) – в кінцевий момент запису




Термограми тестового зразка №3: а) – в початковий момент запису, б) – на половині тривалості нагріву, в) – в кінцевий момент запису




ДОДАТОК Б


Зміна MSE під час навчання мереж для обробки експериментальних результатів активного теплового контролю тестового зразка №1: а) – мережа класифікації, б) – мережа визначення глибини, в) – мережа визначення розкриву



а)



б)



в)

ДОДАТОК В

Список публікацій здобувача за темою дисертації та відомості про апробацію результатів дисертації

За темою дисертаційних досліджень опубліковано 14 наукових праць, з них: 5 статей у наукових фахових виданнях (з них 1 стаття у виданні іноземної держави, 4 статті у виданнях України), 9 матеріалів та тез доповідей на міжнародних та національних науково-технічних конференціях (з яких 2 включені до міжнародних науково-метричних баз).

1. Момот А.С. Реалізація нейромережових алгоритмів класифікації технічного стану композиційних матеріалів за результатами акустичного контролю / А. С. Момот, Р. М. Галаган. // Техническая диагностика и неразрушающий контроль. – 2017. – №1. – С. 43–46.

Здобувачем розроблено нейромережеву систему класифікації технічного стану композиційних матеріалів, обґрунтовано ефективність застосування нейронних мереж в якості систем підтримки прийняття рішень у неруйнівному контролі.

2. Момот А.С. Аналіз методів цифрової обробки термограм / А. С. Момот , Р. М. Галаган. // Вісник Національного технічного університету України "Київський політехнічний інститут". Серія приладобудування. – 2018. – №55. – С. 108–117. (Входить до WorldCat, РИНЦ, Index Copernicus, BASE, OpenAIRE та інших)

Здобувачем проведено аналітичний огляд існуючих методів цифрової обробки термограм, встановлено переваги використання нейронних мереж перед традиційними методами

3. Momot A. S. Analysis of application of neural networks to improve the reliability of active thermal NDT / A. S. Momot, R. M. Galagan. // KPI Science News. – 2019. – №1. – pp. 7–14. (Входить до WorldCat, Index Copernicus, BASE, OpenAIRE та інших)

Здобувачем проведено комп'ютерне моделювання активного теплового контролю сталеві пластини та обґрунтовано можливість підвищення достовірності контролю із застосуванням нейронних мереж.

4. Momot A. S. Statistical analysis of thermal nondestructive testing data / A. S. Momot, R. M. Galagan. // Advanced Information Systems. – Kharkiv. – 2019. – №3. – pp. 58–62.

Здобувачем проведено кореляційний, регресійний та дисперсійний аналіз взаємозв'язків між інформативними параметрами теплового контролю.

5. Momot A. Influence of architecture and training dataset parameters on the neural networks efficiency in thermal nondestructive testing / A. Momot, R. Galagan. // Sciences of Europe. – 2019. – №44. – pp. 20–25. (Входить до Index Copernicus та інших)

Здобувачем проведено формування навчальних множин вхідних даних з різними характеристиками, навчено моделі нейронних мереж та встановлено вплив розглянутих параметрів на ефективність розробленої системи.

6. Momot A. S. The use of ART-2 neural network for processing information signals of non-destructive testing / A.S. Momot, R.M. Galagan. // proc. 2017 IEEE First Ukraine Conference on Electrical and Computer Engineering (UKRCON) Kiev, 29 May-2 June 2017 / IEEE. – 2017. – pp. 981–985.

Здобувачем обґрунтовано можливості застосування нейронних мереж для обробки інформаційних сигналів неруйнівного контролю, реалізовано та досліджено алгоритми нейронної мережі для класифікації технічного стану об'єкту.

7. Момот А.С. Застосування нейромережових технологій для вирішення обернених задач неруйнівного контролю / А. С. Момот, Р. М. Галаган. // XVI Міжнародна науково-технічна конференція «Приладобудування: стан і перспективи», 16-17 травня 2017 р., м. Київ, Україна : збірник тез доповідей. – Київ: КПІ ім. Ігоря Сікорського, 2017. – С. 144.

Здобувачем проаналізовано сучасний стан та тенденції розвитку методів вирішення зворотних задач теплового неруйнівного контролю, обґрунтовано необхідність застосування нейронних мереж в задачах теплової дефектометрії.

8. Момот А.С. Теплова томографія із застосуванням штучних нейронних мереж / А. С. Момот, Р. М. Галаган. // XVII Міжнародна науково-технічна конференція «Приладобудування: стан і перспективи», 15-16 травня 2018 р., м. Київ, Україна : збірник тез доповідей. – Київ : КПІ ім. Ігоря Сікорського, 2018. – С. 178-179.

Здобувачем обґрунтовано можливість застосування нейронних мереж для побудови теплових томограм, проведено комп'ютерне моделювання процесу теплової дефектометрії із застосуванням нейронних мереж.

9. Momot A. S. The Use of Backpropagation Artificial Neural Networks in Thermal Tomography / A.S. Momot, R.M. Galagan. // proc. 2018 IEEE First International Conference on System Analysis & Intelligent Computing (SAIC) Kiev, 8-12 October 2018 / IEEE. – 2018. – pp. 1–6.

Здобувачем обґрунтовано доцільність використання нейронних мереж зворотного поширення помилки в задачах теплової томографії, проведено комп'ютерне моделювання процесу активного теплового контролю та побудовано теплову томограму.

10. Момот А. С. Нейромережева система теплової дефектометрії / А. С. Момот. // II науково-технічна конференція “НК в контексті асоційованого членства України в ЄС” 15-19 жовтня 2018, м. Люблін, Польща: збірник тез доповідей. – Люблін: УТ НКТД, 2018. – С. 23-26.

11. Момот А.С. Статистический анализ взаимосвязей между информативными параметрами активного теплового неразрушающего контроля / А. С. Момот, Р. М. Галаган. // Приборостроение-2018: материалы 11-й Международной научно-технической конференции, 14-16 ноября 2018 года, Минск, Республика Беларусь. – Минск: БНТУ, 2018. – С. 139-141.

Здобувачем проведено комп'ютерне моделювання активного теплового контролю, здійснено кореляційний, регресійний та дисперсійний аналіз взаємозв'язків інформативних параметрів теплового контролю.

12. Momot A. S. Thermal defectometry of composite materials using artificial neural networks / A. S. Momot. // XVIII Міжнародна науково-технічна конференція

«Приладобудування: стан і перспективи», 15-16 травня 2019 р., м. Київ, Україна: збірник тез доповідей. – Київ : КПІ ім. Ігоря Сікорського, 2019. – С. 154-155.

13. Momot, A. Defect classification in active thermal testing with the use of neural networks / A. Momot // Матеріали III науково-технічної конференції «Неруйнівний контроль в контексті асоційованого членства України в Європейському Союзі» з міжнародною участю – NDT – UA 2019, 17-19 вересня 2019 року, м. Київ, Україна. – Київ : УТ НКТД, 2019. – С. 16-18

14. Момот, А. С. Дослідження ефективності нейронних мереж в активному тепловому контролі в залежності від характеристик навчальної вибірки / А. С. Момот, Р. М. Галаган // 9-а Національна науково-технічна конференція і виставка «Неруйнівний контроль та технічна діагностика – UkrNDT-2019», 19-21 листопада 2019 р., м. Київ, Україна: збірник доповідей. – Київ : УТ НКТД, 2019. – С. 229-231.

Здобувачем проведено навчання нейронних мереж класифікації та визначення глибини залягання і розкриття дефектів, встановлено вплив обсягу та якості навчальної вибірки на результати роботи відповідних мереж.

Апробація результатів дисертації.

Основні положення та результати роботи доповідались та обговорювались на таких конференціях:

- Міжнародні науково-технічні конференції «Приладобудування: стан і перспективи», м. Київ, 2017 – 2019 рр.
- Міжнародна науково-технічна конференція «IEEE First Ukraine Conference on Electrical and Computer Engineering (UKRCON)», м. Київ, 2017 р.;
- Міжнародна науково-технічна конференція «НК в контексті асоційованого членства України в ЄС», м. Люблін, 2018 р.;
- Міжнародна науково-технічна конференція «IEEE First International Conference on System Analysis & Intelligent Computing (SAIC)», м. Київ, 2018 р.;
- Міжнародна науково-технічна конференція «Приборостроение-2018», м. Мінськ, 2018 р.

- Міжнародна науково-технічна конференція «НК в контексті асоційованого членства України в ЄС», м. Київ, 2019 р.;
- 9-а Національна науково-технічна конференція і виставка «Неруйнівний контроль та технічна діагностика – UkrNDT-2019», м. Київ, 2019 р.