

МІНІСТЕРСТВО ОСВІТИ І НАУКИ УКРАЇНИ  
НАЦІОНАЛЬНИЙ УНІВЕРСИТЕТ «ЛЬВІСЬКА ПОЛІТЕХНІКА»

Кваліфікаційна наукова праця  
на правах рукопису

**ПЕЛЕЩАК ІВАН РОМАНОВИЧ**

УДК 004.032.26

**ДИСЕРТАЦІЯ**  
**СИСТЕМА РОЗПІЗНАВАННЯ МУЛЬТИСПЕКТРАЛЬНИХ ОБРАЗІВ НА**  
**ОСНОВІ ОСЦИЛЯТОРНИХ НЕЙРОННИХ МЕРЕЖ**

124 *Системний аналіз*

12 Інформаційні технології

Подається на здобуття наукового ступеня доктора філософії

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

Пелешак І.Р.

Науковий керівник  
Литвин Василь Володимирович,  
доктор технічних наук, професор

Львів – 2021

## АНОТАЦІЯ

*Пелещак І. Р.* Система розпізнавання мультиспектральних образів на основі осциляторних нейронних мереж. – Кваліфікаційна наукова праця на правах рукопису.

Дисертація на здобуття наукового ступеня доктора філософії за спеціальністю 124 *Системний аналіз* (12 Інформаційні технології). – Національний університет «Львівська політехніка», Львів, 2021.

### Зміст анотації

У дисертаційній роботі на основі методології системного аналізу розроблено систему розпізнавання та шифрування мультиспектральних образів на основі осциляторних нейронних мереж. Методами системного аналізу (у процесі декомпозиції, аналізу і синтезу та концептуального моделювання) досліджено структуру і властивості штучних нейронних мереж з лінійними та нелінійними осциляторними нейронами; розроблено: метод стиску вхідних образів у нейронній мережі внаслідок діагоналізації матриці вагових синаптичних зв'язків; метод шифрування інформації з постійно змінним асиметричним ключем для кожного нового вхідного образу, який базується на синтезі діагоналізованої нейромережі та алгоритму AES (Advanced Encryption Standard (Rijndael)) і на синтезі нелінійних осциляторних нейронів з топологією ланцюжка і кільця; метод розпізнавання мультиспектральних образів осциляторною нейромережею на основі інформаційного резонансу; модель оптимізації розміру (число нейронів, число синаптичних зв'язків) у межах нелінійної узагальненої похибки; а також на мові Python розроблена програма для розпізнавання мультиспектральних образів на основі інформаційного резонансу за допомогою тришарової осциляторної нейронної мережі та проведено комп'ютерний експеримент розрахунку параметра складності (кількість операцій виконаних нейромережею) навчання тришарової нейронної мережі та її оптимального розміру.

Робота складається зі вступу, чотирьох розділів, висновків, списку посилань та додатків. У першому розділі викладено вичерпний аналіз співвідносних темі дослідження наукових публікацій, проаналізовано моделі штучних нейронних мереж із осциляторними нейронами; розглянуто нейромережеві технології розпізнавання осциляторних і мультиспектральних образів, стиснення даних, шифрування інформації.

У другому розділі розроблено: метод стиску вхідних образів на основі діагоналізації матриці вагових синаптичних зв'язків; метод шифрування на основі синтезу діагоналізованої нейронної мережі й алгоритму AES; нелінійну модель оптимізації розміру багатошарової нейронної мережі в межах узагальненої похибки; та доведено модифіковану теорему Хехт-Нільсена для діагоналізованої нейронної мережі.

У третьому розділі розроблено математичні моделі нейронних мереж з лінійними та нелінійними осциляторними нейронами; досліджено трансформацію морфології нестационарних вхідних образів нелінійним осциляторним нейроном та осциляторною нейронною мережею; запропоновано метод шифрування ланцюговою та кільцевою мережами нелінійних осциляторних нейронів; розроблено методи розпізнавання мультиспектральних образів осциляторною нейронною мережею на основі ефекту інформаційного резонансу та нейроголографічною мережею.

У четвертому розділі викладено результати комп'ютерного експерименту із застосуванням нейронних мереж, зокрема, на мові Python розроблена програма для розпізнавання мультиспектральних образів на основі інформаційного резонансу за допомогою тришарової осциляторної нейронної мережі та проведено комп'ютерний експеримент розрахунку параметра складності (кількість операцій виконаних нейромережею) навчання тришарової нейронної мережі та її оптимального розміру (число нейронів, число синаптичних зв'язків).

Актуальність дослідження обґрунтовано стрімким зростанням об'єму даних у процесі розв'язку задач Data Mining (ідентифікація нестационарних хаотичних процесів, кластеризація, захист комп'ютерних систем, інтелектуальне керування,

діагностика станів біосистем, прогнозування, емуляція, розпізнавання супутникової інформації, розпізнавання та шифрування мультиспектральних вхідних образів), що вимагає розробки нових нейромережових систем, які забезпечать: розпізнавання мультиспектральних образів з амплітудою сигналу, співмірною рівню шуму; збільшення коефіцієнту стиску інформації нейронною мережею; зменшення використовуваного обчислювального ресурсу і часу налаштування вагових коефіцієнтів синаптичних зв'язків нейронної мережі; оптимізацію структури багат шарової нейронної мережі; підвищення ступеня криптостійкості нейромереж. Зазначені проблеми свідчать про теоретичну і практичну актуальність досліджуваної тематики та про необхідність розробки системи розпізнавання й шифрування мультиспектральних образів на основі осциляторних нейронних мереж.

Новизну основних наукових результатів дисертаційного дослідження сформульовано внаслідок теоретико-практичного підходу при розробленні системи розпізнавання і шифрування мультиспектральних образів на основі осциляторних нейронних мереж.

***Вперше розроблено*** метод стиску вхідних образів на основі діагоналізації матриці вагових синаптичних зв'язків нейронної мережі, який, на відміну від методів стиску інформації повнозв'язною нейронною мережею, дав змогу зменшити час налаштування синаптичних зв'язків у процесі навчання нейронної мережі та збільшити коефіцієнт стиску вхідних образів.

***Вперше розроблено*** метод розпізнавання мультиспектральних образів на основі інформаційного резонансу, який, на відміну від методу, що використовує осциляторні нейронні мережі, які не мають власних частот коливань, дає змогу розпізнавати сигнали з амплітудою співмірною рівню шуму.

***Удосконалено*** метод шифрування інформації ланцюговою, кільцевою нейромережами з нелінійними осциляторними нейронами та на основі синтезу діагоналізованої нейронної мережі й алгоритму AES, який, на відміну від методу, що застосовує недіагоналізовану нейронну мережу, дає змогу використовувати

постійно змінний асиметричний ключ нейромережі для кожного окремого вхідного образу.

*Розвинуто* нелінійну модель оптимізації структури багатошарової нейронної мережі прямого поширення з мінімальною похибкою узагальнення, яка на відміну від лінійної дає змогу зменшити похибку визначення оптимального числа синаптичних зв'язків і оптимального числа нейронів у прихованому шарі на 20% у випадку, коли число синаптичних зв'язків є не більшим числа навчальних прикладів.

### **Ключові слова**

діагоналізація синаптичних зв'язків, осциляторна нейронна мережа, інформаційний резонанс, мультиспектральні образи, розпізнавання, шифрування.

## ABSTRACT

*Peleshchak I. R.* Multispectral image recognition system based on oscillatory neural networks. – Qualifying scientific work on the rights of the manuscript.

The dissertation for obtaining a scientific degree of the Doctor of Philosophy on the specialty 124 *System analysis* (12 – Information technologies). – Lviv Polytechnic National University, Lviv, 2021.

### Abstract content

In the dissertation work on the basis of the methodology of system analysis the system of recognition and encryption of multispectral images on the basis of oscillatory neural networks is developed. The structure and properties of artificial neural networks with linear and nonlinear oscillatory neurons has been studied by the methods of system analysis (in the process of decomposition, analysis and synthesis and conceptual modeling); a method of compression of input images in a neural network due to diagonalization of a matrix of weight synaptic connections has been developed; a method for encrypting information with a constantly changing asymmetric key for each new input image has been developed, which is based on the synthesis of a diagonalized neural network and the AES (Advanced Encryption Standard (Rijndael)) algorithm; a method of information encryption based on nonlinear oscillatory neurons with a chain and ring topology has been developed; a method for recognizing multispectral images by an oscillatory neural network based on information resonance has been developed; a model for optimizing the size (number of neurons, number of synaptic connections) within a nonlinear generalized error has been developed; in Python developed a program for recognition of multispectral images based on information resonance using a three-layer oscillatory neural network; conducted a computer experiment to calculate the parameter of the complexity of learning a three-layer neural network (the number of operations performed by the neural network) and its optimal size.

The work consists of an introduction, four chapters, conclusions, a list of references and appendices. The first chapter presents: a comprehensive analysis of the

relevant research topics of scientific publications, analyzes models of artificial neural networks with oscillatory neurons; considers neural network technologies for recognition of oscillatory and multispectral images, data compression, information encryption.

In the second chapter: a method for compressing input images based on diagonalization of the matrix of weight synaptic connections has been developed; an encryption method has been developed based on the synthesis of a diagonalized neural network and the AES algorithm; a nonlinear model for optimizing the size of a multilayer neural network within the generalized error range has been developed; a modified Hecht-Nielsen theorem for a diagonalized neural network has been proved.

In the third chapter: mathematical models of neural networks with linear and nonlinear oscillator neurons has been developed; examines the transformation of the morphology of non stationary input images by a nonlinear oscillator neuron and an oscillator neural network; a method for encrypting nonlinear oscillator neurons with a chain and ring network has been proposed; methods for recognizing multispectral images has been developed by an oscillator neural network based on the effect of information resonance and a neuroholographic network.

The fourth chapter presents the results of a computer experiment using neural networks, in particular, in Python developed a program for the recognition of multispectral images based on information resonance using a three-layer oscillatory neural network and conducted a computer experiment to calculate the parameter of the complexity of learning a three-layer neural network (the number of operations performed by the neural network) and its optimal size.

The relevance of the study is justified by the rapid growth of data in the process of solving Data Mining (identification of nonstationary chaotic processes, clustering, protection of computer systems, intelligent control, diagnostics of biosystem states, forecasting, emulation, recognition of satellite information, recognition and encryption of multispectral input images) problems that require the development of new neural network systems that will provide: recognition of multispectral images with a signal amplitude commensurate with the noise level; increase the compression ratio of the

neural network; reduction of computing resources used and time to adjust the weights of synaptic connections of the neural network; optimization of the structure of the multilayer neural network; increase the degree of cryptographic stability of neural networks. These problems indicate the theoretical and practical relevance of the research topic and the need to develop a system for recognition and encryption of multispectral images based on oscillatory neural networks.

The novelty of the main scientific results of the dissertation research is formulated as a result of the theoretical and practical approach in the development of the system of recognition and encryption of multispectral images on the basis of oscillatory neural networks.

*For the first time*, a method for compressing input images based on diagonalization of the matrix of weight synaptic connections of a neural network was developed, which, unlike methods for compressing information by a fully connected neural network, made it possible to reduce the time for setting up synaptic connections in the process of training a neural network and increase the compression ratio of input images.

*For the first time*, a method for recognizing multispectral images based on information resonance has been developed, which, unlike the method that uses oscillator neural networks that do not have their own oscillation frequencies, makes it possible to recognize signals with an amplitude commensurate with the noise level.

*Improved* the method of information encryption by chain, ring neural networks with nonlinear oscillator neurons and based on the synthesis of a diagonalized neural network and the AES algorithm, which, unlike the method that uses a non-diagonalized neural network, allows you to use a constantly changing asymmetric neural network key for each individual input image.

*Developed* a nonlinear model for optimizing the structure of a multilayer neural network of direct propagation with minimal generalization error, which in contrast to the linear allows to reduce the error of determining the optimal number of synaptic connections and the optimal number of neurons in the latent layer by 20% when the number of synaptic connections is not more educational examples.



**Keywords**

diagonalization of synaptic connections, oscillatory neural network, information resonance, multispectral images, recognition, encryption.

## Список публікацій здобувача

*Наукові праці, в яких опубліковані основні наукові результати дисертації*

*Статті у фахових виданнях України, які входять до міжнародних наукометричних баз:*

1. Пелещак Р. М., Литвин В. В., **Пелещак І. Р.** Динаміка нелінійного осциляторного нейрона при дії зовнішнього нестационарного сигналу. *Радіоелектроніка, інформатика, управління*. 2017. №4. С. 97–105.
2. Peleshchak R., Lytvyn V., **Peleshchak I.**, Doroshenko M., Olyvko R. Hechth–Nielsen theorem for a modified neural network with diagonal synaptic connections. *Mathematical Modeling and Computing*, 2019. Vol. 6(1). P. 101–108.

*Статті у фахових виданнях України:*

3. Пелещак Р. М., Литвин В. В., **Пелещак І. Р.**, Висоцька В. А. Розробка штучної нейронної мережі з осциляторними нейронами для розпізнавання спектральних образів. *Вісник Національного університету «Львівська політехніка». Інформаційні системи та мережі*, 2020. Вип. 7. С. 16–23.

*Статті у наукових періодичних виданнях інших держав:*

4. Peleshchak R., Lytvyn V., Bihun O., **Peleshchak I.** Structural transformations of incoming signal by a single nonlinear oscillatory neuron or by an artificial nonlinear neural network. *International Journal of Intelligent Systems and Applications (IJISA)*, 2019. Vol. 11(8). P. 1–10.

*Статті у наукових періодичних виданнях інших держав, які входять до міжнародних наукометричних баз:*

5. Vasyl Lytvyn, Victoria Vysotska, **Ivan Peleshchak**, Ihor Rishnyak, Roman Peleshchak. Time Dependence of the Output Signal Morphology for Nonlinear Oscillator Neuron Based on Van der Pol Model. *International Journal of Intelligent Systems and Applications (IJISA)*, 2018. Vol. 10(4). P. 8–17.

6. Peleshchak R., Lytvyn V., **Peleshchak I.**, Olyvko R., Korniak J. Decision making model based on neural network with diagonalized synaptic connections. *Advances in Intelligent Systems and Computing*, 2019. Vol. 853. P. 321–329.
7. Lytvyn V., Vysotska V., Shakhovska N., Mykhailyshyn V., Medykovskyy M., **Peleshchak I.**, Fernandes V., Peleshchak R., Shcherbak S. A smart home system development. *Advances in Intelligent Systems and Computing*, 2020. Vol. 1080. P. 804–830.
8. Makara S., Chyrun L., Burov Y., Rybchak Z., **Peleshchak I.**, Peleshchak R., Holoshchuk R., Kubinska S., Dmytriv A. An intelligent system for generating end-user symptom recommendations based on machine learning technology. *CEUR Workshop Proceedings*, 2020. Vol. 2604. P. 844–883.
9. **Ivan Peleshchak**, Roman Peleshchak, Vasyl Lytvyn, Jan Kopka, Mariusz Wrzesien, Janusz Korniak, Janusz Kolbusz, Pawel Rozycki. Spectral Image Recognition Using Artificial Dynamic Neural Network in Information Resonance Mode. *A2IA 2020: International Conference on Artificial Intelligence and Industrial Applications*, 2020. P. 313–322.

*Матеріали міжнародних наукових та науково-практичних конференцій, збірники яких входять до міжнародних наукометричних баз:*

10. Vasyl Lytvyn, **Ivan Peleshchak**, Roman Peleshchak. The compression of the input images in neural network that using method diagonalization the matrices of synaptic weight connections. *2017 2nd International Conference on Advanced Information and Communication Technologies (AICT)*, 2017. P. 66–70.
11. Vasyl Lytvyn, **Ivan Peleshchak**, Roman Peleshchak. Increase the speed of detection and recognition of computer attacks in combined diagonalized neural networks. *2017 4th International Scientific-Practical Conference Problems of Infocommunications. Science and Technology (PIC S&T)*, 2017. P. 152–155.
12. Vasyl Lytvyn, **Ivan Peleshchak**, Roman Peleshchak, Roman Holoshchuk. Detection of multispectral input images using nonlinear artificial neural networks. *2018 14th International Conference on Advanced Trends in Radioelectronics, Telecommunications and Computer Engineering (TCSET)*, 2018. P. 119–122.

13. Lytvyn V., **Peleshchak I.**, Peleshchak R., Kuzyk O. Size optimization of the Multilayer Neural Network in the Framework of the Nonlinear Generalized Error Model. *2019 9th International Conference on Advanced Computer Information Technologies*, 2019. P. 221–225.
14. Lytvyn V., **Peleshchak I.**, Peleshchak R., Vysotska V. Information Encryption Based on the Synthesis of a Neural Network and AES Algorithm. *2019 3rd International Conference on Advanced Information and Communications Technologies*, 2019. P. 447–450.

*Колективна монографія:*

15. Roman Peleshchak, **Ivan Peleshchak**, Victoria Vysotska. Methods for recognizing multispectral images based on neural networks. *LAP Lambert Academic Publishing*, 2020. 152 p.

*Патент на корисну модель:*

16. Патент на корисну модель. Пелещак Р. М., Литвин В. В., **Пелещак І. Р.** Спосіб шифрування цифрової інформації на основі синтезу діагоналізованої нейронної мережі та AES. Національний університет «Львівська політехніка». U 2021 01284. № 3320/ЗУ/21.

*Наукові праці, які додатково відображають наукові результати дисертації:*

17. Zdebskyi P., Vysotska V., Peleshchak R., **Peleshchak I.**, Demchuk A., Krylyshyn M. An application development for recognizing of view in order to control the mouse pointer. *CEUR Workshop Proceedings*, 2019. Vol. 2386. P. 55–74.
18. Lytvyn V., Vysotska V., Mykhailyshyn V., **Peleshchak I.**, Peleshchak R., Kohut I. Intelligent system of a smart house. *2019 3rd International Conference on Advanced Information and Communications Technologies*, 2019. P. 282–287.
19. Lytvyn V., Vysotska V., **Peleshchak I.**, Basyuk T., Kovalchuk V., Kubinska S., Rusyn B., Pohreliuk L., Chyrun L., Salo T. Identifying Textual Content Based on Thematic Analysis of Similar Texts in Big Data. *IEEE 2019 14th International Scientific and Technical Conference on Computer Sciences and Information Technologies*, 2019. P. 84–91.

20. Bekesh R., Chyrun L., Kravets P., Demchuk A., Matseliukh Y., Batiuk T., **Peleshchak I.**, Bigun R., Maiba I. Structural modeling of technical text analysis and synthesis processes. *CEUR Workshop Proceedings*, 2020. Vol. 2604. P. 562–589 .
21. Husak V., Lozynska O., Karpov I., **Peleshchak I.**, Chyrun S., Vysotskyi A. Information system for recommendation list formation of clothes style image selection according to user's needs based on NLP and chatbots. *CEUR Workshop Proceedings*, 2020. Vol. 2604. P. 788–818.

## ЗМІСТ

ПЕРЕЛІК УМОВНИХ ПОЗНАЧЕНЬ.....	16
ВСТУП.....	17
РОЗДІЛ 1. СТРУКТУРА І ВЛАСТИВОСТІ ШТУЧНИХ НЕЙРОННИХ МЕРЕЖ.....	25
1.1. Аналіз моделей штучних нейронних мереж з осциляторними нейронами..	25
1.2. Аналіз нейромережєвих технологій розпізнавання осциляторних і мультиспектральних образів.....	35
1.3. Аналіз способів стиснення даних.....	45
1.4. Аналіз технологій нейронних мереж в задачах шифрування інформації....	54
Висновки до розділу 1.....	57
РОЗДІЛ 2. СТИСК ТА ШИФРУВАННЯ ВХІДНИХ ОБРАЗІВ МЕТОДОМ ДІАГОНАЛІЗАЦІЇ МАТРИЦІ ВАГОВИХ СИНАПТИЧНИХ ЗВ'ЯЗКІВ У НЕЙРОННІЙ МЕРЕЖІ.....	58
2.1. Стиск вхідних образів на основі методу діагоналізації матриці вагових синаптичних зв'язків.....	58
2.2. Модифікована теорема Хехт-Нільсена для нейронної мережі з діагоналізованими синаптичними зв'язками.....	64
2.3. Нелінійна модель оптимізації розміру багат шарової нейронної мережі в межах узагальненої похибки.....	68
2.4. Шифрування інформації на основі синтезу діагоналізованої нейронної мережі та алгоритму AES.....	74
Висновки до розділу 2.....	82
РОЗДІЛ 3. ОСЦИЛЯТОРНІ НЕЙРОННІ МЕРЕЖІ З ЛІНІЙНИМИ ТА НЕЛІНІЙНИМИ ОСЦИЛЯТОРНИМИ НЕЙРОНАМИ.....	83
3.1. Математична модель нейронної мережі з лінійними осциляторними нейронами. Критерій виникнення інформаційного резонансу.....	83
3.2. Математична модель нейронної мережі з нелінійними осциляторними нейронами.....	87

3.3. Шифрування інформації ланцюговою та кільцевою мережами з нелінійними осциляторними нейронами.....	94
3.4. Розпізнавання спектральної інформації на основі синтезу модифікованих осциляторних нейронних мереж та голографічних методів обробки даних.....	109
Висновки до розділу 3.....	116
РОЗДІЛ 4. РЕЗУЛЬТАТИ КОМП'ЮТЕРНОГО ЕКСПЕРИМЕНТУ З ВИКОРИСТАННЯМ НЕЙРОННИХ МЕРЕЖ.....	117
4.1. Програмна реалізація розпізнавання мультиспектральних образів за допомогою осциляторної нейронної мережі.....	117
4.2. Чисельний розрахунок параметра складності навчання тришарової нейронної мережі та її оптимального розміру.....	130
Висновки до розділу 4.....	135
ВИСНОВКИ.....	136
СПИСОК ВИКОРИСТАНОЇ ЛІТЕРАТУРИ.....	139
ДОДАТОК А. Список публікацій здобувача за темою дисертації та відомості про апробацію результатів дисертації.....	160
ДОДАТОК Б. Акти впровадження результатів дисертації.....	166
ДОДАТОК В. Повний код програми нейронної мережі.....	169

**ПЕРЕЛІК УМОВНИХ ПОЗНАЧЕНЬ**

AES	Advanced Encryption Standard (Rijndael)
DES	Data Encryption Standard
АКФ	автокореляційна функція;
ШПФ	швидке перетворення Фурє;
ВП	віддалений портрет;
ЛА	літальний апарат;
РЛС	радіолокаційна станція;
ПЦ	повітряна ціль;
RBF	Radial Basis Functions;
НВ	навчальна вибірка;
PNN	Probabilistic Neuron Networks;
ШНМ	штучна нейронна мережа;
ЗНМ	згорткова нейронна мережа;
RLE	Run-length encoding;
LZW	Алгоритм Лемпеля – Зіва – Велча;
JBIG	Joint Bi-level Image Experts Group;
JPEG	Joint Photographic Experts Group.



## ВСТУП

**Актуальність теми.** Зростання об'єму даних у процесі розв'язку задач Data Mining (ідентифікація нестационарних хаотичних процесів, кластеризація, захист комп'ютерних систем, інтелектуальне керування, діагностика станів біосистем, прогнозування, емуляція, розпізнавання супутникової інформації, розпізнавання та шифрування мультиспектральних вхідних образів) вимагає розробки нових нейромережових методів, які забезпечать зменшення обчислювального ресурсу і часу налаштування вагових коефіцієнтів синаптичних зв'язків під час навчання нейронної мережі та оптимізують спосіб розв'язку системи диференціальних рівнянь для опису нейронних мереж з нелінійними осциляторними нейронами.

Існуючі способи зменшення обчислювального ресурсу і часу налаштування синаптичних зв'язків під час навчання нейронної мережі (багатошаровий перцептрон з топологією у вигляді «пляшкового горла», мережа Хопфілда, мережа Кохонена, дискретно-косинусне перетворення, вейвлетна компресія) мають ряд обмежень. Зокрема: втрата частини інформації через зменшення кількості нейронів у прихованих шарах; відносно невеликий об'єм пам'яті; зменшення ступеня розпізнавання образів внаслідок запису великої їх кількості; низька ефективність при стиску незначного обсягу даних.

Усунути такі обмеження можна за допомогою методу діагоналізації матриці синаптичних зв'язків у базисі вхідних образів та оптимізації структури багатошарової нейронної мережі в межах нелінійної моделі узагальненої похибки.

Після відкриття того, що осциляторний хаос у мозку людини є його нормальним способом діяльності [1], розпочалися наукові дослідження нейронних мереж, що функціонують в складних осциляторних режимах. Було запропоновано осциляторні та хаотичні нейронні мережі для розпізнавання осциляторних образів [2 – 4]. Значна частина моделей осциляторних мереж імітують роботу нейронів без прив'язки до розв'язування практичних задач.

У розвиток теорії осциляторних мереж вагомий внесок зробила група учених (Я. Казакевич, Р. Борисюк, Є. Тіхонов, Й. Курамото), які зосередились саме на біологічно правдоподібному моделюванню роботи та еволюції нейронних

мереж на основі моделі нейрона Ходжкіна-Хакслі, спрощеною версією якої є осциляторний нейрон Фітц Х'ю-Нагумо. Було побудовано модель зорової кори головного мозку, яка дозволила сегментувати прості зображення, використовуючи осцилятори Ван дер Поля, і була призначена для розв'язування вже практичної задачі – сегментації зображень. Проте, на базі цих моделей осциляторних нейронів не розглядався підхід щодо розпізнавання мультиспектральних образів (мультиспектральних електромагнітних сигналів), що випромінюють осциляторні об'єкти та не було ураховано число імпульсів сигналу, які подаються на вхід нейронів та час релаксації нейрона після потенціалу його дії.

Подальший розвиток лінійної та нелінійної моделей нейронних мереж з осциляторними нейронами, які мають власні частоти, пов'язаний з ефектом інформаційного резонансу щодо задач розпізнавання мультиспектральних образів.

Існуючі технології штучних нейронних мереж [5] є ефективним методом криптографічного захисту інформації, проте ключ шифрування (синаптичні зв'язки) не змінюється для різних за природою вхідних образів, а швидкість шифрування інформації достатньо низька.

Для підвищення ступеня криптостійкості алгоритму порівняно з існуючими алгоритмами шифрування доцільно розробити постійно змінний ключ. Система шифрування інформації на основі синтезу діагоналізованої нейронної мережі та алгоритму AES забезпечить формування індивідуального ключа для кожного нового вхідного образу.

Проаналізовані вище проблеми свідчать про теоретичну і практичну актуальність досліджуваної тематики та про необхідність розробки системи розпізнавання й шифрування мультиспектральних образів на основі осциляторних нейронних мереж.

**Зв'язок роботи з науковими програмами, планами, темами.** Тема дисертації відповідає науковому напрямку кафедри інформаційних систем та мереж Національного університету «Львівська політехніка»: Системи штучного

інтелекту та інженерія знань (дослідження і розвиток систем штучного інтелекту та інженерія знань, розроблення моделей систем штучного інтелекту та інженерія знань, методи та засоби побудови інформаційного забезпечення задач систем штучного інтелекту, інформаційне забезпечення процесів аналізу та прийняття рішень в задачах систем штучного інтелекту).

Дисертаційне дослідження виконане в межах держбюджетних науково-дослідних робіт:

- «Методи та засоби функціонування систем підтримки прийняття рішень на основі онтологій» (номер державної реєстрації 0118U000269; терміни виконання роботи: 01.2018 – 12.2019 р.);
- «Система підтримки прийняття рішень розпізнавання мультиспектральних образів на основі технологій машинного навчання та онтологічного підходу» (номер державної реєстрації 0120U102203; терміни виконання роботи: 04.2020 – 12.2021 р.).

**Мета і завдання дослідження.** Метою дисертаційного дослідження є розробка системи розпізнавання та шифрування мультиспектральних образів на основі осциляторних нейронних мереж для ідентифікації та класифікації нестационарних процесів з підвищеною завадостійкістю до шумів.

Для досягнення поставленої мети вирішено такі завдання:

- розроблено метод стиску вхідних образів без втрат інформації на основі діагоналізації матриці вагових синаптичних зв'язків;
- побудовано математичну модель осциляторної нейронної мережі з лінійними та нелінійними осциляторними нейронами, проаналізовано трансформацію осциляторною нейронною мережею морфології нестационарних вхідних образів і визначено критерії виникнення інформаційного резонансу;
- розроблено метод розпізнавання мультиспектральних образів осциляторною нейронною мережею на основі інформаційного резонансу;
- удосконалено методи шифрування інформації ланцюговою, кільцевою мережами нелінійних осциляторних нейронів та на основі синтезу діагоналізованої нейронної мережі й алгоритму AES;

- розвинуто нелінійну модель оптимізації структури багат шарової нейронної мережі на основі мінімізації нелінійної узагальненої похибки, яка базується на принципі мінімальної довжини опису.

**Об'єктом дослідження** є процес розпізнавання та шифрування мультиспектральних образів на основі осциляторних нейронних мереж.

**Предметом дослідження** є лінійна та нелінійна моделі осциляторних нейронних мереж для розпізнавання та шифрування мультиспектральних образів.

**Методи дослідження.** Для розв'язання сформульованих задач застосовано головні методи системного аналізу: *побудова моделі системи* розпізнавання та шифрування мультиспектральних образів на основі нейронних мереж з лінійними та нелінійними осциляторними нейронами та *аналіз цієї нейронної системи* на основі побудованої моделі способами декомпозиції, аналізу, синтезу та концептуального моделювання. У процесі декомпозиції визначено завдання розробки *методу стиску* на основі діагоналізації матриці вагових синаптичних зв'язків штучної нейронної мережі; *методу розпізнавання мультиспектральних образів* осциляторною нейромережею на основі інформаційного резонансу; *методу шифрування інформації* з постійно змінним асиметричним ключем для кожного нового вхідного образу, який базується на синтезі діагоналізованої нейромережі та алгоритму AES і на синтезі нелінійних осциляторних нейронів з топологією ланцюжка і кільця. У процесі аналізу нейронної системи з лінійними та нелінійними осциляторними нейронами визначено її *архітектуру, властивості, переваги та недоліки*; розроблено *алгоритм перетворення* вхідних мультиспектральних образів нейронною мережею з лінійними та нелінійними осциляторними нейронами за допомогою системи лінійних та нелінійних осциляторних рівнянь. У процесі синтезу нейронної системи побудовано *архітектуру* тришарової нейронної мережі з осциляторними нейронами з сигмоїдною функцією активації у прихованому шарі та стрибкоподібної функції активації у вихідному шарі; у межах *евклідової метрики* сформульовано *критерій виникнення інформаційного резонансу* в осциляторній нейронній мережі. У ході концептуального моделювання розроблено *математичні моделі* тришарової

нейромережі з лінійними та нелінійними осциляторними нейронами та осциляторної нейромережі з топологією ланцюжка і кільця; у межах нелінійної узагальненої похибки розроблено *модель оптимізації розміру* (число нейронів, число синаптичних зв'язків) багат шарової нейромережі; на мові Python розроблена *програмна реалізація* розпізнавання мультиспектральних образів за допомогою тришарової осциляторної нейронної мережі та проведено *чисельний розрахунок параметра складності* (кількість операцій, виконаних нейромережею) навчання тришарової нейронної мережі та її оптимального розміру.

**Наукова новизна отриманих результатів.** Внаслідок теоретико-практичного підходу при розробленні системи розпізнавання і шифрування мультиспектральних образів на основі осциляторних нейронних мереж:

*Вперше розроблено* метод стиску вхідних образів на основі діагоналізації матриці вагових синаптичних зв'язків нейронної мережі, який, на відміну від методів стиску інформації повнозв'язною нейронною мережею, дав змогу зменшити час налаштування синаптичних зв'язків у процесі навчання нейронної мережі та збільшити коефіцієнт стиску вхідних образів.

*Вперше розроблено* метод розпізнавання мультиспектральних образів на основі інформаційного резонансу, який, на відміну від методу, що використовує осциляторні нейронні мережі, які не мають власних частот коливань, дає змогу розпізнавати сигнали з амплітудою співмірною рівню шуму.

*Удосконалено* метод шифрування інформації ланцюговою, кільцевою нейромережами з нелінійними осциляторними нейронами та на основі синтезу діагоналізованої нейронної мережі й алгоритму AES, який, на відміну від методу, що застосовує недіагоналізовану нейронну мережу, дає змогу використовувати постійно змінний асиметричний ключ нейромережі для кожного окремого вхідного образу.

*Розвинуто* нелінійну модель оптимізації структури багат шарової нейронної мережі прямого поширення з мінімальною похибкою узагальнення, яка на відміну від лінійної дає змогу зменшити похибку визначення оптимального числа синаптичних зв'язків і оптимального числа нейронів у прихованому шарі на

20% у випадку, коли число синаптичних зв'язків є не більшим числа навчальних прикладів.

**Практичне значення отриманих результатів** полягає у можливості їх застосування у галузі системного аналізу для розроблення й побудови моделей складних інформаційних систем і систем підтримки прийняття рішень та впровадження цих моделей засобами комп'ютерного моделювання. Зокрема, запропоновані методи мають таке науково-практичне значення:

- Метод стиску вхідних образів на основі діагоналізації матриці вагових синаптичних зв'язків може бути використаний для зменшення часу налаштування синаптичних зв'язків у процесі навчання нейронної мережі завдяки зменшенню числа синаптичних зв'язків з  $\tilde{N}_\lambda^2$  до  $\tilde{N}_\lambda$  (при умові, що кількість нейронів  $N$  у шарах нейромережі є однаковою) та для збільшення коефіцієнта стиску вхідних образів відносно повнозв'язної нейронної мережі в  $O\left(\frac{2\tilde{N}_\lambda}{\tilde{N}_\lambda + 1}\right)$  разів.

- Осциляторна нейронна мережа може бути використана як розпізнавач радіолокаційних діаграм розсіяння сигналів за критерієм резонансу.

- Модифікована теорема Хехт-Нільсена для діагоналізованої тришарової нейронної мережі дає змогу апроксимувати функцію від  $n$  змінних із заданою точністю  $\varepsilon > 0$ , за допомогою однієї агрегації агрегування.

- Для шифрування вхідних інформаційних сигналів та захисту інформації від атак по стороннім каналам з підвищеним ступенем криптостійкості запропоновано метод шифрування вхідних інформаційних сигналів на основі ланцюгової та кільцевої нелінійної нейронної мережі, що базується на частотній модуляції, та метод шифрування інформації на основі синтезу алгоритму AES та нейронної мережі з діагоналізованими синаптичними зв'язками, що змінюють морфологію асиметричного ключа шифрування для кожного окремого вхідного образу.

- Нелінійна модель оптимізації структури багатошарової нейронної мережі може бути безпосередньо використана для оцінки параметра складності навчання

нейронної мережі (кількість операцій виконаних нейронною мережею) та вибору оптимального часу її навчання залежно від числа навчальних прикладів та числа синаптичних зв'язків.

**Особистий внесок здобувача.** Дисертація є самостійною науковою працею, у якій автором особисто розроблено нові наукові ідеї та результати, що дозволили вирішити наукове завдання розробки системи розпізнавання та шифрування мультиспектральних образів на основі осциляторних нейронних мереж. Робота містить прикладні положення та висновки, сформульовані дисертантом особисто. Ідеї, положення чи гіпотези інших авторів, які наявні в дисертації, мають відповідні посилання і використані лише для підсилення ідей та результатів здобувача.

**Апробація результатів дисертації.** Основні результати дисертаційного дослідження апробовано на міжнародних наукових та науково-практичних конференціях та наукових семінарах кафедри інформаційних систем та мереж:

- *2017 2nd International Conference on Advanced Information and Communication Technologies (AICT)*, 2017. Location: Lviv, Ukraine.
- *2017 4th International Scientific-Practical Conference Problems of Infocommunications. Science and Technology (PIC S&T)*, 2017. 10–13 October, 2017. Kharkov, Ukraine.
- *2018 14th International Conference on Advanced Trends in Radioelectronics, Telecommunications and Computer Engineering (TCSET)*, 2018. Location: Lviv-Slavske, Ukraine.
- *2019 9th International Conference on Advanced Computer Information Technologies*, 2019. Jun. 05–07, 2019. Czech Republic–Ceske Budejovice.
- *2019 3rd International Conference on Advanced Information and Communications Technologies*, 2019. Location: Lviv, Ukraine.
- *2019 3rd International Conference on Advanced Information and Communications Technologies (AICT 2019)*. 2–6 July 2019, Lviv, Ukraine.

- *IEEE 2019 14th International Scientific and Technical Conference on Computer Sciences and Information Technologies (CSIT 2019)*. September 17–20, 2019, Lviv. Polytechnic National University (Lviv, Ukraine).

- Наукові семінари кафедри інформаційних систем та мереж (2018 – 2021 рр.)

**Публікації.** У 21 наукових публікаціях повністю відображені основні результати дисертації, з них: 1 монографія (зарубіжне наукове видання), 2 статті у фахових виданнях України, що входять до міжнародних наукометричних баз (з них 1 індексується у базі Scopus, 1 у базі Web of Science), 1 стаття у фаховому виданні України, 5 статей у наукових періодичних виданнях інших держав, що входять до наукометричної бази Scopus, 1 стаття у науковому періодичному виданні іншої держави, 5 матеріалів міжнародних наукових та науково-практичних конференції, які індексуються у базі Scopus, 1 патент на корисну модель, 5 наукових праць, які додатково відображають наукові результати дисертації.

**Структура і обсяг дисертації.** Дисертаційна робота викладена на 171 сторінці та складається з анотації, змісту, переліку скорочень, вступу, чотирьох основних розділів, у яких міститься 48 рисунків, списку використаних джерел із 154 найменувань та трьох додатків. Структура, мова та стиль викладу дисертації відповідає вимогам МОН України до оформлення дисертації. Робота написана українською мовою з використанням сучасної наукової термінології, стиль викладу матеріалу послідовний та логічний.



## РОЗДІЛ 1. СТРУКТУРА І ВЛАСТИВОСТІ ШТУЧНИХ НЕЙРОННИХ МЕРЕЖ

### 1.1. Аналіз моделей штучних нейронних мереж з осциляторними нейронами

Упродовж останніх років з'явилась достатня технічна база для реалізації осциляторних нейронних мереж, тому актуальності набув напрямок їх розробки [6 – 8]. Крім того, завдяки тому, що принцип роботи осциляторної нейронної мережі можна наблизити до принципу роботи нервової системи людини, це дозволить розв'язувати ряд складних задач штучного інтелекту. Загальновідомо, що коли сумарний зовнішній вхідний сигнал біологічного нейрона перевищує пороговий рівень, тоді генерується послідовність імпульсів, а коли значення суми величин зовнішніх сигналів є меншим від порогового рівня, тоді нейрон імпульсів не формує. Відомо [6 – 9], що біологічні нейрони можуть генерувати від одного до кількох сотень імпульсів за секунду. Дані імпульси здебільшого мають однакову амплітуду, тому інформація, яку передають біологічні нейрони, формується густиною імпульсів (кількість імпульсів за секунду або частотою імпульсів). Поріг збудження нейрона є пропорційний частоті генерації імпульсів, а число сформованих імпульсів залежить від інтенсивності, тривалості вхідних сигналів та від властивостей нейрона.

Осцилятор – це множина взаємозв'язаних функціонуючих елементів (нейронів або нейронних ансамблів), що здатні працювати у коливальному режимі. З погляду математичного моделювання осциляторні нейронні мережі зручно представляти у вигляді окремих, взаємодіючих між собою осциляторів.

Винятковою особливістю осциляторних нейронних мереж є наявність у їх структурі збуджувальних та гальмівних нейронів (нейронних популяцій), що різняться за характером дії: збуджувальні нейрони збільшують, а гальмівні зменшують активність інших елементів мережі.

Осциляторна нейронна мережа описується системою диференціальних (або різницевих) рівнянь, інколи з випадковим шумом. Таких рівнянь може бути декілька десятків або сотень залежно від архітектури біологічних нейронів [10,

11]. Якщо моделювання проводиться на рівні нейронних популяцій, то зазвичай беруть від 2 до 5 рівнянь, які описують усереднену за ансамблем динаміку кожної популяції [12, 13]. У випадку фазового осцилятора розглядається тільки одна змінна – фаза коливань [14, 15].

Залежно від архітектури зв'язків між осциляторними нейронами розглядають два типи осциляторних нейронних мереж:

1. *Повнозв'язні осциляторні нейронні мережі.* У такому разі кожний осциляторний нейрон зв'язаний зі всіма іншими осциляторними нейронами.
2. *Осциляторні нейронні мережі з локальними зв'язками.* У цьому разі кожний осциляторний нейрон зв'язаний тільки з осциляторними нейронами з деякого околу фіксованого радіуса. Інколи враховують часові затримки у зв'язках між нейронами.

При моделюванні динаміки осциляторних нейронних мереж найчастіше зустрічаються з такими двома проблемами:

1. Якою моделлю можна описати динаміку коливань нейрона у формі  $\delta$ -подібних піків (шипів) та вибухів?
2. Як взаємодіють нейрони?

Частковий розв'язок цих проблем був вирішений наступними моделями осциляторних нейронів, які формують коливання у формі шипів та вибухів [16 – 17].

Зокрема, модель осциляторної нейронної мережі типу «*integrate-and-fire*» [16], яка описується диференціальним рівнянням:

$$\frac{dV}{dt} = I + a - bV, \text{ якщо } V < V_{\text{пор.}}, \quad (1.1.1)$$

$$V \leftarrow c, \text{ якщо } V \geq V_{\text{пор.}}, \quad (1.1.2)$$

де  $V$  – потенціал мембрани нейрона;  $I$  – вхідний струм;  $a, b, c, V_{\text{пор.}}$  – параметри осциляторного нейрона. Якщо потенціал мембрани  $V$  набуває порогового значення  $V_{\text{пор.}}$ , тоді нейрон генерує коливання у формі  $\delta$ -подібного піку і потенціалу  $V$  присвоюється значення параметра  $c$ . Операція числового

інтегрування (1.1.1) дає дискретну часову залежність для потенціалу мембрани нейрона  $V(t+1) = V(t) + I + a - bV(t)$ . Нейрон типу «*integrate-and-fire*» може генерувати коливання у формі шипів з постійною частотою та є інтегратором. Модель має такі недоліки:

- є одновимірною;
- не формує коливань у вигляді фазових  $\delta$ -подібних піків будь-якого типу вибухів;
- має постійний поріг;
- не може мати бістабільних станів;
- у зв'язку з фіксованим порогом коливання у формі  $\delta$ -подібних піків не мають затримок.

Іншою моделлю осциляторного нейрона є модель «*integrate-and-fire*» з *адаптацією* [16], яка описується такими диференціальними рівняннями:

$$\frac{dV}{dt} = I + a - bV + g(d - V), \quad (1.1.3)$$

$$\frac{dg}{dt} = \frac{e\delta(t) - g}{\tau}. \quad (1.1.4)$$

Диференціальне рівняння (1.1.4) описує динаміку змінного порогу. Ця модель збільшує величину активаційної функції  $g$  і генерує зовнішній струм, який зменшує частоту коливань у вигляді  $\delta$ -подібних піків. Модель (1.1.3) з урахуванням (1.1.4) відрізняється від моделі (1.1.1) тим, що має змінний поріг.

У роботі [19] було розглянуто модель «*integrate-and-fire-or-burst*»:

$$\frac{dV}{dt} = I + a - bV + gH(V - V_h)h(V_T - V), \quad (1.1.5)$$

$$V \leftarrow c, \text{ якщо } V = V_{\text{пор.}}, \quad (1.1.6)$$

де  $\frac{dh}{dt} = \begin{cases} \frac{-h}{\tau^-}, \text{ якщо } & V > V_h \\ \frac{1-h}{\tau^+}, \text{ якщо } & V < V_h \end{cases}$  – дезактивація  $T$ -струму кальцію;

$g, V_h, V_T, \tau^+, \tau^-$  – параметри, які описують динаміку  $T$ -струму;  $H$  – функція

Хевісайда. Змінна  $h(t)$  створює можливість для формування коливань у вигляді вибухів та інших режимів функціонування. Однак для імітації моделі «*integrate-and-fire-or-burst*» упродовж 1 мс необхідно від 9 до 13 операцій з плаваючою комою залежно від значення  $V$ .

Модель виду «*resonate-and-fire*» була розглянута в роботі [20], яка є двовимірною ( $z = x + iy \in C$ ) аналоговою моделлю «*integrate-and-fire*». Ця модель описується диференціальним рівнянням 1-го порядку:

$$\frac{dz_i}{dt} = (b_i + i\omega_i)z_i + \sum_{j=1}^n c_{ij}\delta(t - t_j^*), \quad (1.1.7)$$

$$z \leftarrow z_0(z), \text{ якщо } \text{Im} z = a, \quad (1.1.8)$$

де  $z_i \in C$  – описує стан  $i$ -го нейрона;  $b_i + i\omega_i \in C$  – внутрішній параметр нейрона;

$c_{ij} \in C$  – синаптичні коефіцієнти;  $\delta(t - t_j^*) = \begin{cases} 1, & \text{якщо } t = t_j^* \\ 0, & \text{якщо } t \neq t_j^* \end{cases}$  функція Дірака;

$t_j^*$  – перший момент часу «вистрілу»  $j$ -го нейрона;  $\text{Re} z$  є мембранним потенціалом;  $z_0(z)$  довільна функція, яка описує залежність оновлювання стану до нового значення від активності нейрона після формування коливання у вигляді шипа. Можна побачити, що кожен «вистріл» виробляє імпульс, який витісняє активність інших нейронів комплекснозначною константою  $c_{ij}$ . Для імітації коливань протягом 1 мс модель «*resonate-and-fire*» потребує 10 операцій з плаваючою комою, а коли частота коливань наближається до нуля, то ця модель стає інтегратором.

Серед альтернативних моделей нейрона «*integrate-and-fire*» є *квадратична модель «integrate-and-fire»*, яка також відома, як *модель тета-нейрона* [21, 22] або *канонічна модель Ерментроута-Копелла* [23].

$$\frac{dv}{dt} = I + a(v - v_{cn.})(v - v_{nop.}), \quad (1.1.9)$$

$$v \leftarrow v_{скид.}, \text{ якщо } v = v_{нік.}, \quad (1.1.10)$$

де  $v_{cn.}$  і  $v_{пор.}$  – значення мембранного потенціалу нейрона у стані спокою та значення порогу нейрона. Для функціонування нейрона протягом 1 мс ця модель потребує 7 операцій з плаваючою комою. Ця модель може бути використана для опису великих мереж інтеграторів. Залежно від режиму функціонування значення порогу квадратична модель «*integrate-and-fire*» має затримку коливань у формі дельта піків.

У роботі [24, 25] була розглянута модель Іжикевича, яка описує різні форми коливань на основі системи двох диференціальних рівнянь:

$$\begin{cases} \frac{dv}{dt} = 0.04v^2 + 5v + 140 - u + I \\ \frac{du}{dt} = a(bv - u) \end{cases}, \quad (1.1.11)$$

з додатковим так званим після піковим оновленням

$$\begin{cases} v \leftarrow c \\ u \leftarrow u + d \end{cases} \quad \text{якщо} \quad v \geq 30 \text{ мВ}; \quad (1.1.12)$$

де  $v$  і  $u$  – безрозмірні змінні;  $a$ ,  $b$ ,  $c$ ,  $d$  – безрозмірні параметри моделі нейрона. Змінна  $v$  описує мембранний потенціал нейрона, а  $u$  – мембранний потенціал відновлення, який активує іонні струми  $K^+$  і дезактивує іонні струми  $Na^+$  та забезпечує негативний зворотний зв'язок з мембранним потенціалом нейрона  $v$ . При досягненні амплітуди дельта коливань (+30 мВ) потенціал мембрани і змінна мембранного відновлення оновлюються згідно з (1.1.12). Якщо величина  $v$  перевищує значення +30 мВ, тоді вона спочатку скидається до +30 мВ, а потім до  $c$  так, щоб величини усіх шипів були однаковими. Змінна  $I$  моделює постійні синаптичні або зовнішні струми.

Частина  $0.04v^2 + 5v + 140 - u + I$  рівняння (1.1.11) вибирається так, щоб величина  $v$  мала розмірність мВ, а час – мс. Зазначимо, що напруга +30 мВ в (1.1.9) не є пороговою, а є амплітудою піка коливання у формі шипа. Величина порогової напруги моделі лежить між –70 мВ і –50 мВ і є осциляторною, як у біологічних нейронах. При відповідному виборі параметрів  $a$ ,  $b$ ,  $c$  і  $d$  модель може генерувати коливання усіх відомих видів нейронів кори головного мозку [23]. Для

імітації функціонування нейрона протягом 1 мс модель потребує 13 операцій з плаваючою комою, а тому є доволі ефективною при імітації мереж нейронів великої розмірності. Коли  $(a,b,c,d)=(0.2, 2, -56, -16)$  і  $I = -99$ , модель генерує хаотичні коливання. Для досягнення високої точності формування коливань крок інтегрування за часом  $\tau$  повинен бути досить малим.

Недоліками цієї моделі є те, що:

1. Для опису поведінки одного нейрона або мережі нейронів, які генерують коливання у формі шипів, потрібно для кожної окремої архітектури нейромережі підбирати нові параметри.
2. Коли різні нейрони мають різну динаміку, кожному збуджувальному нейрону потрібно приписувати інше значення параметрів, що вимагає збільшення обчислювального ресурсу.
3. Не враховується число імпульсів струму, які подаються на вхід нейронів.
4. Взаємодія нейронів враховується тільки завдяки однієї випадкової змінної, яка однорідно розподілена на інтервалі  $[0, 1]$ , що входить в параметри моделі.

*Модель Фітза Хуга-Нагумо* [26] була створена з урахуванням кубічного ступеня нелінійності потенціалу мембрани нейрона, тобто

$$\begin{cases} \frac{dv}{dt} = a + bv + cv^2 + dv^3 - u \\ \frac{du}{dt} = \varepsilon(ev - u) \end{cases}, \quad (1.1.13)$$

параметри підбирали так, щоб модель описувала динаміку коливань у вигляді шипів багатьох резонаторних нейронів. Ця модель потребує 72 операції з плаваючою комою для імітації функціонування нейрона протягом 1 мс. Оскільки, дана модель є двовимірною системою звичайних диференціальних рівнянь без оновлювання значень, вона не демонструє автономної хаотичної динаміки або коливань у формі вибухів.

*Модель Хіндмарша – Роуза* [27] спрямована на вивчення стрибкоподібної поведінки мембранного потенціалу, що спостерігається в експериментах, проведених з одним нейроном. Ця модель описується трьома нелінійними диференціальними рівняннями:

$$\left\{ \begin{array}{l} \frac{dv}{dt} = u - F(v) + I - w \\ \frac{du}{dt} = G(v) - u \\ \frac{dw}{dt} = \frac{H(v) - w}{\tau} \end{array} \right. , \quad (1.1.14)$$

Залежно від вибору функцій  $F$ ,  $G$  і  $H$  модель (1.1.14), по різному описує нейрообчислювальні потенціали. Однак, проблемою є вибір цих функції для моделі нейрона, який генерує коливання у вигляді регулярних або нерегулярних шипів. Для імітації функціонування нейрона упродовж 1 мс ця модель потребує 120 операцій з плаваючою комою.

*Модель Морріса – Лекара* [28] було запропоновано для опису коливань у м'язових волокнах великого молюска. Дана модель складається з системи рівнянь, рівняння потенціалу мембрани з миттєвою активацією та додаткові рівняння для опису повільної активації.

$$\left\{ \begin{array}{l} I = C \frac{dV}{dt} + g_L(V_L) + g_{Ca}M(V - V_{Ca}) + g_KN(V - V_K) \\ \frac{dM}{dt} = \lambda_M(V)[M_\infty(V) - M] \\ \frac{dN}{dt} = \lambda_N(V)[N_\infty(V) - N] \end{array} \right. , \quad (1.1.15)$$

де  $M_\infty(V) = \frac{1}{2} \left\{ 1 + \tanh \left( \frac{V - V_1}{V_2} \right) \right\}$ ,  $\lambda_M(V) = \bar{\lambda}_M \cosh \left( \frac{V - V_1}{2V_2} \right)$ ,

$N_\infty(V) = \frac{1}{2} \left\{ 1 + \tanh \left( \frac{V - V_3}{V_4} \right) \right\}$ ,  $\lambda_N(V) = \bar{\lambda}_N \cosh \left( \frac{V - V_3}{2V_4} \right)$  – активаційні функції,

$I$  – струм, який підводиться до нейрона. Модель (1.1.15) здатна генерувати різні види коливань у формі дельта-подібних піків, а коливання у вигляді тонізуючих

вибухів може описувати тільки тоді, коли до цієї моделі додати рівняння, яке описує повільну дезактивацію струму  $Ca$ . В останньому модель стає еквівалентною моделі Ходжкіна – Хакслі [29]. Для функціонування нейрона впродовж 1 мс ця модель потребує 600 операцій з плаваючою комою.

У роботі [30] Вільсоном було запропоновано поліноміальну модель нейрона кори головного мозку, яка описується чотирма диференціальними рівняннями поліноміального виду. Ця модель демонструє всі нейрообчислювальні властивості відповідно до вибраних параметрів. Недоліком цієї моделі є те, що з переходом від часового кроку дискретизації 0,1 мс до 0,25 мс втрачається точність визначення діючого потенціалу. Для функціонування нейрона упродовж 1 мс ця модель потребує 180 операцій з плаваючою комою.

Наступною математичною моделлю нейрона, яка описує динаміку потенціалу мембрани нейрона, активацію струмів  $Na$  і  $Ca$  та дезактивацію струму  $Na$  є модель Ходжкіна — Хакслі [29]. Ця модель описується системою чотирьох нелінійних диференціальних рівнянь, які відображають усі нейрообчислювальні властивості. За допомогою цієї моделі можна досліджувати різні режими функціонування нейронів: синаптичне інтегрування, фільтрування дендритів, ефекти морфології дендритів, взаємодія між іонними струмами та інші явища, пов'язані з динамікою нейронів. Оскільки для імітації функціонування нейрона протягом 1 мс модель потребує 1200 операцій з плаваючою комою, тому її можна використовувати тільки для імітації невеликої кількості нейронів.

Для вивчення систем різної топології з великою кількістю осциляторних нейронів ( $N > 103$ ), де реалізується не тільки глобальна синхронізація, а й синхронізація середнім полем, використовуються моделі фазових осциляторних нейронів, зокрема модель Курамото [31, 32]. Динаміка моделі фазового осцилятора Курамото описується рівнянням:

$$\frac{d\theta_i}{dt} = \omega_i + \frac{K}{N} \sum_{j=1}^N \sin(\theta_j - \theta_i), \quad (1.1.16)$$



де  $\theta_i$  – фаза осциляторного нейрона є основною змінною стану ( $0 \leq \theta_i \leq 2\pi$ );  $\omega_i$  – внутрішня частота осцилятора, описує зміщення фази за одиницю часу;  $K$  – сила зв'язку між осциляторними нейронами, є одним з найважливіших параметрів, який впливає на процес синхронізації нейронів;  $N$  – загальна кількість осциляторів в нейромережі. Ця модель була удосконалена в роботі [32], у якій було використано адаптивні сили зв'язку між осциляторами замість статичних сил  $K$ . Вона описується системою двох диференціальних рівнянь:

$$\begin{cases} \frac{d\theta_i}{dt} = \omega_i + \frac{1}{N} \sum_{j=0}^N \sigma_{ij} \sin(\theta_j - \theta_i) \\ \frac{d\sigma_{ij}}{dt} = \mu \sum_{k=0}^N |\sin(\theta_k - \theta_i)| \end{cases}, \quad (1.1.17)$$

де  $\sigma_{ij}$  – адаптивна сила зв'язку між  $i$ -им та  $j$ -им осциляторними нейронами;  $\mu$  – параметр, який описує швидкість адаптації. Уведення адаптивних сил зв'язку у нейромережу дає змогу скоротити час синхронізації в цій мережі. Зокрема, для нейромережі зі структурою «сітка» складність досягнення стану глобальної синхронізації зменшилось з  $O(n^2)$  до  $O(n)$ , а для нейромережі зі структурою «двонаправлений список» з  $O(n^3)$  до  $O(n^2)$ . У роботі зазначається, що збільшення сил зв'язку між осциляторами може негативно відобразитись на вихідних результатах нейромережі з розрідженими зв'язками може привести осциляторну нейромережу в стан «десинхронізації».

Електронно-апаратна реалізація осциляторних нейронних мереж була запропонована на основі осциляторів з термічним зв'язком, які є в матриці діоксиду ванадію [33, 34]. У цій моделі вихідний осциляторний нейрон мережі має багаторівневі варіації значення її синхронізації з опорним осцилятором і дає змогу класифікувати 512 візуальних шаблонів на набір класів з максимальною кількістю елементів до 14. Можливість класифікації мережі залежить від внутрішнього рівня шуму та параметра ефективності синхронізації. Модель дає змогу проектувати багаторівневі вихідні каскади нейронних мереж з високою

пропускною здатністю даних. Математична модель цієї осциляторної нейронної мережі описується системою таких рівнянь:

$$I_{sw\_i} = f_i(U) = \begin{cases} \frac{U_i}{R_{off\_i}}, & \text{якщо } flag_i = 1(OFF) \\ \frac{(U_i - U_{cf\_i})}{R_{on\_i}}, & \text{якщо } flag_i = 0(ON) \end{cases}, \quad (1.1.18)$$

де  $i=0, \dots, 10$  – номер генератора,  $flag$  позначає стан перемикача  $VO_2$ ,  $1(OFF)$  – високий опір, а  $0(ON)$  – низький опір.

Переходи з одного стану в інший можна виразити таким алгоритмом:

$$flag_i = \begin{cases} 1(OFF), & \text{якщо } (flag_i = 0) \text{ і } (U_i < U_{h\_i}) \\ 0(ON), & \text{якщо } (flag_i = 1) \text{ і } (U_i > U_{th\_i}) \end{cases}, \quad (1.1.19)$$

де  $U_{h\_i}$  і  $U_{th\_i}$  – порогові значення включення і утримуючі напруги комутаторів.

З оглянутої літератури випливає, що вищезгадані моделі осциляторних нейронних мереж потребують розробки нових моделей лінійних та нелінійних осциляторних мереж, функціональні властивості яких забезпечать:

1. Розпізнавання мультиспектральних образів осциляторною нейронною мережею на основі інформаційного резонансу.
2. Аналіз та обробку нестационарних вхідних сигналів різної морфології осциляторною нейронною мережею.
3. Врахування часу релаксації нейрона після потенціалу його дії.
4. Зменшення підбору параметрів до одного (рівність частоти зовнішнього сигналу з власною частотою нейрона) для створення інформаційного резонансу.
5. Урахування числа імпульсів сигналу, які подаються на вхід нейронів.

## 1.2. Аналіз нейромережових технологій розпізнавання осциляторних і мультиспектральних образів

Розпізнавання образів – це процедура, яка дає змогу винести рішення про відношення даного образу або його фрагмента до одного з  $N$  класів, де  $N > 1$  [35]. Рішення виносяться на підставі наявності в образі деяких ознак, що належать тому чи іншому класу. Необхідно відзначити, що перед етапом розпізнавання образів зазвичай виконується їх попередня обробка з метою поліпшення вихідного сигналу.

Формально задачу розпізнавання можна записати у вигляді функції  $i = d(\bar{x})$ , де  $i$  – номер класу, до якого належить образ, що розпізнається;  $\bar{x}$  – вектор ознак. Функція  $i = d(\bar{x})$  будується на основі розбиття простору ознак  $U$  на  $N$  класів  $U_i$ , які не перетинаються ( $i = 1, \dots, N$ ):  $U_{i=1}^N$ ,  $U_i = U$ ,  $U_i \cap U_j = \emptyset$  при  $i \neq j$ .

Критерієм вибору функції  $i = d(\bar{x})$  є мінімальна похибка розпізнавання.

Таким чином, можна виділити дві основні проблеми розпізнавання образів [35]:

1. Проблема визначення та добування ознак.
2. Проблема прийняття рішення про відношення певного образу (вектору ознак) до одного з представлених  $N$  класів.

Виділення найбільш інформативних ознак при розробці систем розпізнавання – одна з найважливіших задач теорії і практики розпізнавання образів. Для виділення інформативних ознак потрібно [36]:

1. Зменшити до мінімуму кількість необхідних ознак для опису класів без суттєвого збільшення імовірності похибки розпізнавання;
2. Використовувати прості алгоритми розпізнавання
3. Зменшити ймовірність похибки розпізнавання.

Перший підхід полягає в тому, щоб знайти малу кількість ознак з максимальною інформативністю.

Другий підхід полягає в тому, щоб знайти велике число базових ознак, після чого відповідно до певного критерію ефективності ознак відбирається якнайменша кількість найбільш корисних для розпізнавання ознак. Однак, недоліком цього підходу є відсутність функціональної залежності між критеріями ефективності ознак та ймовірністю похибки розпізнавання.

У теорії розпізнавання образів є два підходи до вирішення задач:

1. Навчання без вчителя;
2. Навчання з вчителем.

В задачах навчання без вчителя, або самонавчання, досліджувана система спонтанно навчається виконати задачу розпізнавання образів без втручання експериментатора. До задач іншого типу відноситься алгоритм навчання, в якому досліджуваній системі надається навчальна вибірка, де зазначено, до якого класу належать її елементи. Ненавчена система проводить розпізнавання образів і порівнює свої результати з правильними відповідями, що поступають від вчителя. За результатами порівняння система коректує параметри функції, яка визначає відношення образу до певного класу.

Існують три основні задачі при розробці систем розпізнавання образів [37]. Перша задача пов'язана з представленням початкових даних, отриманих як результат вимірювань параметрів об'єкта, що розпізнається. Друга задача розпізнавання образів пов'язана з виділенням характерних ознак або властивостей із отриманих початкових даних і зниженням розмірностей векторів образів. Цю задачу називають задачею попередньої обробки та вибору ознак. Третя задача пов'язана з побудовою систем розпізнавання образів та полягає в тому, щоб відшукати оптимальні процедури ідентифікації та класифікації.

Головною особливістю задачі розпізнавання осциляторних образів є те, що вхідний сигнал, який потрібно розпізнати, розглядається не в статиці, а в динаміці. Основна інформація про образ міститься в траєкторії зміни вхідного сигналу з часом. Внаслідок чого образ отримує новий вимір – час, що значно ускладнює розв'язок задачі розпізнавання.

Задача розпізнавання осциляторних образів має велику кількість практичних застосувань:

- Розпізнавання мовлення (тексту, мови, диктора) [38 – 40], мелодій;
- Передбачення часових рядів (фінансові показники, погода);
- Діагностика, ідентифікація об'єктів керування (двигунів, реакторів);
- Розпізнавання рукописного вводу;
- Розпізнавання жестів;
- Детектування руху;
- Медична діагностика електрокардіографії, електроенцефалографії [41];
- Розпізнавання міміки обличчя.

Розглянемо основні підходи до розв'язку задачі розпізнавання осциляторних образів.

1. Визначення часових меж осциляторного образу здебільшого здійснюється неявно і досить часто присутнє в наступних етапах розпізнавання. Для визначення точного моменту початку або кінця осциляторного образу доцільно застосувати класифікатори або каскади класифікаторів, що навчаються (за алгоритмом Віоли-Джонс [42]).

2. Визначення ознак осциляторного образу є найбільш змістовним і визначальним етапом. В процесі статистичного розпізнавання в якості ознак доцільно використовувати:

- а) значення вхідного сигналу від поточного моменту часу за певний період (вікно спостереження) з фіксованим кроком (глибиною);
- б) автокореляційну функцію (АКФ) від вибірки;
- в) частотний спектр – швидке перетворення Фур'є (ШПФ);
- г) вейвлет-ознаки та вейвлет-пакети (Добеши, Койфа).

В ході структурного розпізнавання образів осциляторний образ доцільно розподілити на кластери, кожному з яких відповідатиме певний символ і значення

параметрів. Після цього набір символів та їх параметрів передається класифікаторові.

3. Скорочення розмірності простору ознак відбувається внаслідок використання в якості ознак частотного спектру, автокореляційної функції і вейвлет-коефіцієнтів.

4. Класифікація в ході статистичного розпізнавання здійснюється усіма відомими методами класифікації статичних образів (вважається, що на вході цих алгоритмів будуть сформовані ознаки) – метод  $k$ -найближчих сусідів, узагальнений метод моментів, метод опорних векторів, нейронні мережі.

5. Результати роботи класифікатора сумуються та визначається клас-переможець, в іншому випадку при малому значенні суми приймається рішення про вибір невідомого класу.

Серед актуальних напрямків у теорії та практиці автоматичного розпізнавання протяжних повітряних цілей (літаки, ракети, метеозонди, хмари, дощ, турбулентності атмосфери) – аналізом їх радіолокаційних віддалених портретів (ВП), які називаються в англійській літературі «range profile». Сучасний стан даної сфери досліджень представляють роботи [43 – 59].

Вейвлет-аналіз дає змогу розкрити аспекти даних, які інші методи (зокрема, аналіз Фур'є) аналізу сигналу не розкривають. Зокрема, це пошук тенденцій, точок розривів і самоподібність. Крім цього, він дає змогу побачити різні представлення даних на відміну від традиційних методів [60, 61].

Серед ідей вейвлетного представлення сигналів головна полягає у їх багаторівневій декомпозиції на дві групи: *апроксимуючі* та *деталізуючі*. Перші дають поверхневий опис сигналів, виділяючи у них частини з достатньо повільною динамікою, а інші описують складові з локальною і швидкою динамікою з наступним їх дробленням і деталізацією на наступних рівнях декомпозиції сигналів.

В основі неперервного вейвлет-перетворення лежить використання двох функцій: масштабуючої (скейлінг-функції)  $\varphi(t)$  і материнського вейвлета  $\psi(t)$ .

Перша відповідає умові  $\int_{-\infty}^{\infty} \varphi(t) dt = 1$  і дає змогу отримувати грубе наближення (апроксимацію) сигналу. Друга має нульове середнє  $\int_{-\infty}^{\infty} \psi(t) dt = 0$  і визначає деталі сигналу.

Вейвлет-перетворення одновимірного сигналу – це його представлення у вигляді узагальненого ряду або інтеграла Фур'є по системі базисних функцій  $\psi_{ab}(t) = \frac{1}{\sqrt{a}} \psi\left(\frac{t-b}{a}\right)$ , які утворені з материнського (вихідного) вейвлета  $\psi(t)$  за допомогою операцій зсуву по аргументу  $b$  та зміни масштабу  $a$ . Зауважимо, що норми вейвлетів  $\psi_{ab}(t)$  дорівнюють нормі  $\psi(t)$ , що забезпечує нормувальний множник  $|a|^{-\frac{1}{2}}$ .

Неперервне вейвлет-перетворення сигналу  $f(t) \in L_2(\mathbb{R})$  за змістом відповідає перетворенню Фур'є із заміною гармонічного базису  $\exp(-j\omega t)$  на вейвлетний  $\psi_{ab}(t)$ :  $w(a,b) = \langle f, \psi_{ab} \rangle = \int_{-\infty}^{\infty} f(t) \psi_{ab}(t) dt$ .

Вейвлет-спектрограми більш інформативні від звичайних Фур'є-спектрограм. Вибір аналізуючого вейвлета визначається тим, яку інформацію необхідно видобути із сигналу.

У загальному випадку вейвлет-перетворення на основі вейвлет-функції  $\psi(t)$  може відновити (реконструювати) принаймні тонкі деталі сигналу. Для відновлення повної форми вихідного сигналу  $f(t)$  доводиться також вдаватися до скейлінг-функції  $\varphi(t)$ , яка називається також батьківським вейвлетом. Така ситуація виникає не завжди, а, як правило, у випадку застосування ортогональних вейвлетів.

Ефективність вейвлет-аналізу визначається вибором базисного вейвлета (Морле, Добеші, «мексиканська шляпа» та інші).

Дослідження, проведені у роботі [56], показують, що використання морфологічних, геометричних і вейвлетних характеристик ВП у ролі інформативних ознак дозволяють успішно виконувати розпізнавання повітряних цілей (ПЦ).

У загальному випадку кортеж (упорядкований набір елементів) всіх інформативних ознак ПЦ включає всі три типи характеристик ВП:

$$\bar{x} = (\bar{x}_1, \bar{x}_2, \bar{x}_3), \quad (1.2.2)$$

де  $\bar{x}_1$  – кортеж морфологічних ознак,  $\bar{x}_2$  – кортеж геометричних ознак,  $\bar{x}_3$  – кортеж вейвлетних ознак.

Потрібно зазначити, що надлишкова вхідна інформація про об'єкти спостереження може суттєво ускладнити алгоритми їх класифікації. З огляду на це безсумнівний науковий інтерес становлять питання оптимального комплектування інформативних ознак розглянутого типу для інженерного проектування систем автоматичного розпізнавання ПЦ.

Задачі класифікації осциляторних образів можна реалізувати на основі технології штучних нейронних мереж. У роботі [57] досліджено функціональні можливості класифікації за допомогою радіально-базисних (RBF – Radial Basis Functions) нейронних мереж.

RBF – мережі відносяться до класу мереж прямого поширення. Архітектура мережі представлена двома шарами нейронів (*Рис. 1.2.1*), без врахування вхідного шару, який виконує роль розподільника вхідних сигналів. Приховані нейрони реалізують радіальні базисні функції активації.






Рис. 1.2.1. Архітектура мережі RBF

Радіально-базисні функції мають вигляд

$$\phi(\bar{x}) = F(\|\bar{x} - \bar{c}\|), \quad (1.2.3)$$

де  $\bar{c}$  – центр функції, причому подвійні прямі дужки  $\|\ \|\$  позначають норму вектора. Передбачається, що функція монотонно спадає з віддаленням від центра  $\bar{c}$ . Її можна інтерпретувати як потенціал.

Найбільш поширеним видом радіальних функцій активації є функція Гауса [6]:

$$\phi(\bar{x}) = \exp\left(-\frac{\|\bar{x} - \bar{c}\|^2}{2\sigma^2}\right), \quad (1.2.4)$$

де  $\sigma$  – параметр, який визначає розмір активної області функції.

У нейронній мережі функція активації  $j$ -го нейрона  $\phi_j(\bar{x})$  визначається його центром  $c_j$ . Вихід мережі формується вихідним шаром лінійних нейронів:

$y = \sum_{j=1}^K \omega_{ij} \phi_j(\bar{x}), i = 1:m$ . Таким чином, він визначається матрицею вагових коефіцієнтів  $\bar{\Omega} = [\omega_{ij}]$ .

Роль прихованих нейронів полягає в групуванні вхідних векторів на  $K$  класів, причому кожен клас обмежений в просторі вхідних векторів деякою ізопотенціальною поверхнею  $\phi_j(\bar{x}) = \text{const} > 0$ , яка охоплює центр класу  $c_j$ .

У процесі навчання відбувається кластеризація навчальної вибірки (НВ) з виділенням  $K$  класів, область локалізації яких визначається відповідною радіальною функцією  $\phi_j(\bar{x})$ . Процес кластеризації на кожній ітерації передбачає виділення радіального нейрона, вектор ваг якого в найменшому степені відрізняється від вектора  $\bar{x}$ , і зміщення вектора ваг даного нейрона в бік цього вектора. При цьому застосовуються різні міри близькості векторів, серед яких найчастіше зустрічається евклідова.

Після закінчення розділення вхідного простору відбувається налаштування вагової матриці  $\bar{\Omega}$  вихідного шару. Задача його навчання зводиться до мінімізації розбіжності фактичної реакції мережі і бажаної.

Роздільне навчання передбачає спочатку розділення вхідного простору на кластери в радіальному шарі, а пізніше – навчання з учителем вихідного лінійного шару.

Процес навчання мережі RBF зводиться:

- до підбору параметрів  $c_j, \sigma_j$  та форми базисних функцій;
- до підбору ваг нейронів вихідного шару.

Частинним випадком RBF – мереж є *імовірнісні нейронні мережі* (PNN – Probabilistic Neuron Networks) [62]. У структурі мереж PNN другий шар на відміну від мереж RBF представлений нейронами конкуруючого типу, які підраховують умовну імовірність приналежності вхідного вектора до одного з вихідних класів. При цьому активується тільки нейрон, сумарне значення вхідних сигналів якого найбільше. Тому як функція активації вихідних нейронів застосовується порогова.

Характерною ознакою PNN є те, що кількість нейронів прихованого шару береться рівним числу елементів навчальної вибірки. Таким чином, враховуючи вплив кожного прикладу із НВ, роль другого шару зводиться до об'єднання в задані класи груп вхідних векторів із НВ.

Розпізнавання мультиспектральних образів здійснюють на основі перетворення зображення в частотну область за допомогою просторових фільтрів. Статистика спектральної інформації в різних масштабах та орієнтацій визначає ознаки зображення. Цей підхід був добре досліджений при обробці зображень і були досягнені практичні результати [63 – 65]. Просторовий фільтр може стати селективним, способом підсилення певних частот при заглушенні інших. Цей селективний вибір певних частот складно контролювати в згорткових нейронних мережах (ЗНМ). Хоча ЗНМ є універсальними апроксиматорами, на практиці не зрозуміло, чи ЗНМ можуть навчитися виконувати спектральний аналіз з наявними наборами даних. Замість того, щоб покладатися на ЗНМ, які можуть навчитися виконувати спектральний аналіз, автори [66] пропонують безпосередньо інтегрувати спектральні підходи до ЗНМ, особливо на основі кратномасштабного (мультирезоляційного) аналізу із використанням вейвлет-перетворень [67].

Згорткові нейронні мережі [68 – 73] відомі завдяки тому, що вони добре фіксують просторові особливості, тоді як спектральний аналіз [65, 74] добре фіксує масштабонезалежні (або масштабо-інваріатні) ознаки на основі спектральної інформації.

У роботі [66] було запропоновано класифікацію зображень та розпізнавання просторових і спектральних об'єктів, яка здійснюється на основі вейвлет згорткових нейронних мереж. Ця модель дає змогу отримати спектральну інформацію, яка втрачається у звичайних загорткових нейронних мережах [68, 69]. Експерименти показують [66], що вейвлет-ЗНМ можуть досягти більшої точності в розпізнаванні просторових та спектральних образів, ніж існуючі моделі, при цьому маючи значно меншу кількість параметрів, ніж звичайні ЗНМ. Вейвлет-ЗНМ мають практичну цінність у двох складних задачах: класифікація текстур та анотація зображень.

Математична модель вейвлет-ЗНМ описується співвідношенням  $y = (\bar{x} \cdot \bar{k}) \downarrow q$ , де узагальнені ваги  $k$  визначають як:

- При  $\bar{k} = \bar{\omega}$  та  $q = 1$  (згортка)

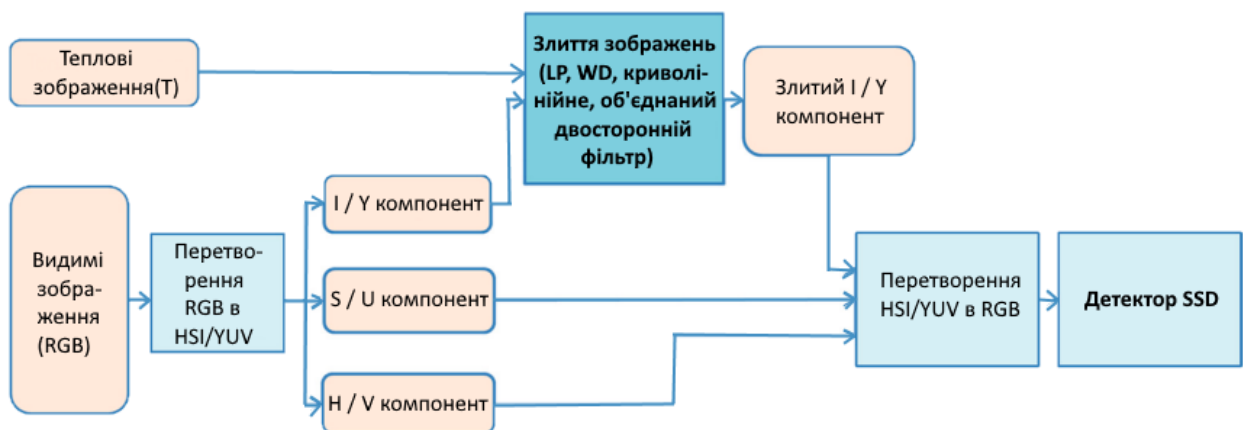
- При  $\bar{k} = \bar{p}$  та  $q > 1$  (пулінг)
- При  $\bar{k} = \bar{\omega} \cdot \bar{p}$  та  $q > 1$  (згортка після якої слідує пулінг)

$\bar{k} = \left( \frac{1}{q}, \dots, \frac{1}{q} \right) \in R^q$  – описує усереднений фільтр; квантор  $\downarrow$  описує операцію

децимації. Середній пулінг математично означає згортку використовуючи  $\bar{k}$ , за чим слідує децимація з кроком  $q$ .

Вейвлет-ЗНМ містить високочастотні та низькочастотні фільтри у ролі ядер згортки для того, щоб слідувати конвенції кратномасштабного аналізу. Для вейвлет перетворень застосовувались вейвлети Гаара.

Розпізнавання мультиспектральних образів у видимому та інфрачервоному діапазонах на основі глибинних ЗНМ запропоновано у роботах [70 – 73, 75]. Для об'єднання видимого зображення та сегментованого теплового зображення був використаний двосторонній фільтр. Сегментація теплового зображення використовувалась для усунення ефектів фонових областей образів та для полегшення подальшого розпізнавання образів на основі відмінностей між зображеннями [76]. Блок-схема об'єднання зображення об'єкта у видимому та інфрачервоному діапазонах подана на *Рис. 1.2.2*.



*Рис. 1.2.2. Блок-схема методів об'єднання зображення об'єкта у видимому та інфрачервоному діапазонах*

Рівняння, яке описує об'єднання зображень на основі двостороннього фільтра, записується у вигляді:

$$F_p = \frac{1}{k(p)} \sum_{p' \in \Omega} g_d(p' - p) g_r(A_{2p} - A_{2p'}) A_{1p'}, \quad (1.2.5)$$

де  $F_p$  – інтенсивність точки  $p$  на об'єднаному зображенні у видимому та інфрачервоному спектрах;  $A_{1p'}$  – інтенсивність точки  $p'$  на основному зображенні;  $A_{2p}$  – інтенсивність при  $p$  на другорядне зображенні. Видимі зображення важливі для денного виявлення об'єктів, а інфрачервоні зображення відіграють важливу роль у нічних детекторах. Для збереження більшої частини інформації на видимих зображеннях, в денний час компонента  $Y$  (YUV) у видимих зображень використовується як основне зображення  $A_1$ , а інфрачервоне зображення використовується як другорядне зображення  $A_2$ . У нічний час інфрачервона компонента використовується як  $A_1$  (основне зображення), а компонент  $Y$  – як  $A_2$  (другорядне зображення). В об'єднаному двосторонньому фільтрі ваги складаються з двох функцій: функція просторової ділянки  $g_d$  та функція наближення до краю  $g_r$ . Функція  $g_d$  визначає відстань між пікселями, тоді як функція  $g_r$  визначає різницю щільності в  $A_2$ . Як правило, ці функції мають Гаусову форму, а параметри їх стандартного відхилення є  $\sigma_d$  та  $\sigma_r$ , відповідно.  $\Omega$  – ділянка сусіднього вікна навколо пікселя  $p$ , а  $k(p)$  – коефіцієнт нормалізації.

Отже, у роботах [70 – 73, 75] зосереджено увагу на дослідженні розпізнавання мультиспектральних об'єктів на основі ЗНМ в залежності від вибору методу об'єднання зображень та виявленні їх ефективності на підставі взаємодоповнення та різноманітності комбінацій.

### 1.3. Аналіз способів стиснення даних

Стиснення даних – це процедура перекодування даних, яка проводиться з метою зменшення їхнього обсягу, розміру, об'єму.

У класифікації інформації, зокрема можна виділити таку, що розподіляється на критичну до точності передачі даних, відносно критичну та некритичну. Критичність залежить від обсягу корисної інформації на одиницю (байт)

фактичної. Залежно від рівня критичності даних алгоритми поділяються на втратне та безвтратне стиснення.

Стиснення без втрат (англ. Lossless) – метод стиснення даних, при використанні якого закодована інформація може бути відновлена з точністю до біта. Для кожного з типів цифрової інформації, як правило, існують свої алгоритми стиснення без втрат.

Стиснення з втратами (англ. Lossy compression) – метод стиснення даних, при якому розпакований файл відрізняється від оригіналу, проте є корисним для використання. Стиснення із втратами найчастіше використовується для мультимедійних даних, особливо для потокової передачі даних та телефонії.

Стосовно сфери застосування методи стиснення поділяються на:

- методи загального призначення;
- спеціалізовані методи.

Множину методів стиснення даних подано у вигляді класифікаційного дерева (Рис. 1.3.1).

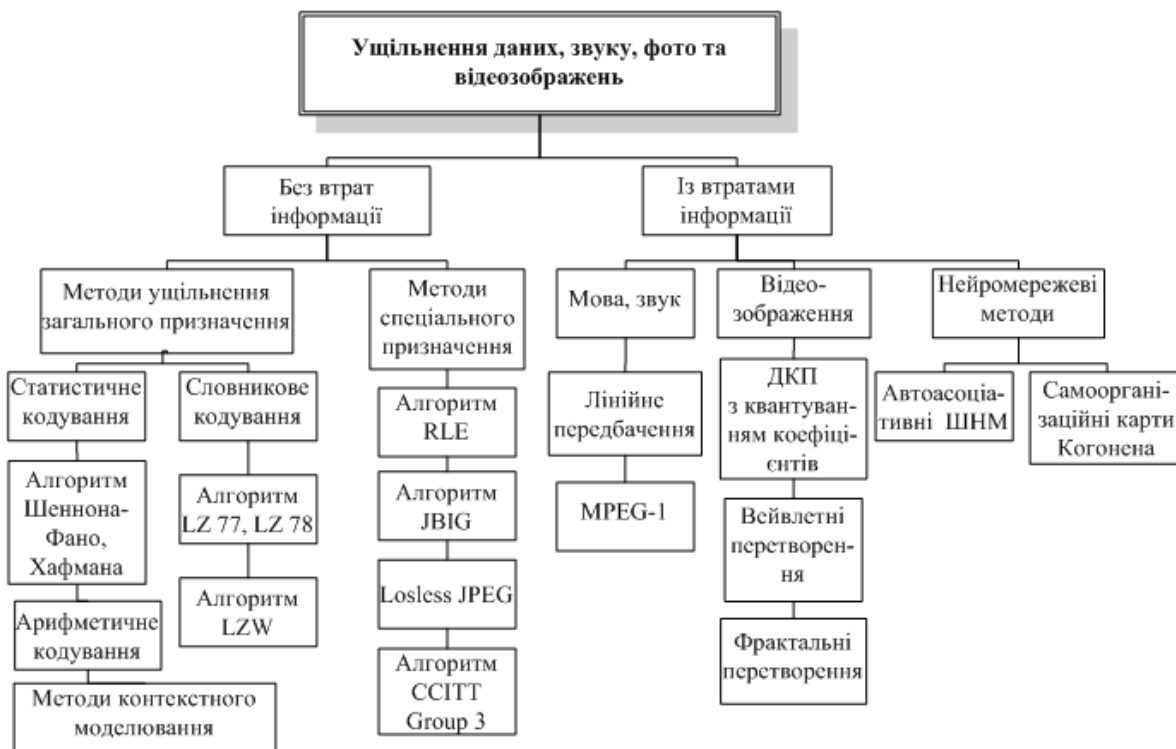



Рис. 1.3.1. Методи ущільнення даних

Штучні нейронні мережі забезпечують здійснення компресії інформації завдяки властивостям узагальнення (генералізації), забезпечують отримання значних коефіцієнтів компресії, демонструючи цим переваги над існуючими традиційними методами стиснення [77]. Зокрема, метод стиску інформації на основі тришарової нейронної мережі (автоенкодер) був запропонований авторами роботи [78, 79].



*Рис. 1.3.2. Автоенкодер*

У цьому методі структура тришарового перцептрона складається з наступних параметрів: число нейронів вхідного та вихідного шарів однакове ( $N_{input} = N_{output}$ ), а число нейронів прихованого шару значно менше ( $N_{hidden} \ll N_{input}$ ). Унаслідок навчання перцептрон може відтворити на виході нейронної мережі такий самий вектор  $\bar{x}$  за розмірністю, який подається на нейрони у вхідному шарі. Такий перцептрон автоматично здійснює стиск (компресію) інформації. На нейронах прихованого шару виникає представлення кожного вектора, яке значно коротше, ніж довжина вектора, що подається на вхід. Припустимо, що деякий набір векторів потрібно передавати по лінії зв'язку, попередньо стискаючи інформацію і тим самим, зменшуючи число каналів, які необхідні для передачі інформації. Передача стиснутої інформації по каналах здійснюється таким чином: на одному кінці лінії зв'язку поміщаємо вхідний і прихований шар перцептрона, а результат роботи нейронів прихованого шару (короткі за довжиною вектори) будемо передавати по лінії зв'язку; на другому

кінці лінії розмістимо копію прихованого шару і вихідного шару перцептрона, тоді переданий короткий вектор з нейронів прихованого шару перейде на нейрони вихідного шару, де буде відтворений вхідний вектор (декомпресія).

Методи стиснення даних на основі виділення частотних областей, застосування вейвлетів та фрактальних перетворень орієнтовані виключно на певні об'єкти застосування – зображення, звукові файли та інше. Нейромережеві методи з використанням моделі геометричних перетворень [80, 81] володіють більшою універсальністю та має такі властивості:

- можливість здійснення ущільнення даних та їх відновлення для широкого діапазону коефіцієнта компресії;
- раціональне поєднання показників компресії та якості відновлюваних даних;
- можливість здійснення ущільнення без втрат інформації;
- досить високі показники швидкодії.

Особливість даного методу компресії полягає у представленні скомпресованих даних у форматі чисел з фіксованою комою, що дають змогу доповнити базовий нейромережевий метод додатковими засобами, які підвищують коефіцієнт ущільнення та покращують якість відтворюваних даних [80].

Реалізувати алгоритм моделі геометричних перетворень можна за допомогою багатошарового перцептрону прямого поширення (*Рис. 1.3.3*), який навчений відтворювати вхідні сигнали на виході. Кількість входів такої мережі збігається з кількістю виходів, а кількість нейронів прихованого шару є меншою, що дає змогу стискати дані, зменшуючи їхню розмірність. Цей підхід одночасно реалізує стандартний алгоритм виділення головних компонент (Карунена-Лоева) [82, 83], оскільки метод аналізу головних компонент базується на використанні багатошарових нейронних мереж автоасоціативного типу, які побудовані на основі моделі геометричних перетворень.






Рис. 1.3.3. Автоасоціативна нейронна мережа геометричних перетворень

Для задач стиснення зображень можливими є два варіанти: навчання і застосування мережі на одному і тому самому зображенні; навчання на певному еталонному зображенні та застосування навченої раніше нейромережі в режимі використання для ущільнення і відновлення інших зображень.

Навчання нейромережі геометричних перетворень, яка працює в автоасоціативному режимі здійснюється на основі вхідної матриці, елементами якої є яскравості пікселів  $x_{i,j}$ . Кожен рядок матриці відповідає вхідному вектору, зокрема окремому блоку зображення розміром  $n \times n$  пікселів (Рис. 1.3.4).




Рис. 1.3.4. Вибір блоку зображення

Загальна кількість векторів (кількість блоків зображення) дорівнює  $M$ , а кількість ознак-пікселів векторів (стовпців матриці) дорівнює  $N$ .

$$x_{i,j} = \left\{ \begin{array}{cccc} x_1 & x_2 & \dots & x_N \\ \cdot & \cdot & \dots & \cdot \\ \cdot & \cdot & \dots & \cdot \\ \cdot & \cdot & \dots & \cdot \end{array} \right\}, \text{ де } i = \overline{1, M}, j = \overline{1, N}. \quad (1.3.1)$$

Для істотного підвищення коефіцієнта стиску був запропонований метод еталонного зображення для навчання нейронної мережі з подальшим її використанням для тестових зображень.

На вхід нейронної мережі для навчання подається певне еталонне зображення підвищеної складності. Питання вибору еталону докладно розглянуто у [84].

Параметри нейромережі, отримані в процесі навчання на еталонному зображенні, зберігаються в пам'яті комп'ютера та надалі використовуються для виділення головних компонент рухомих зображень. Кількість перетворень (кількість нейронів прихованого шару) під час навчання на еталонному зображенні  $k$  дорівнює кількості кроків, які необхідні для виділення головних компонент тестового зображення.

Операція стиснення-відновлення зображення здійснюється за таким алгоритмом:

1. Знаходимо базовий рядок для центрованих елементів масиву:

$$xB_j^{(k)} \approx \max_i \left\{ \sum_{j=1}^n \left( x1_{i,j}^{(k)} \right)^2 \right\}.$$

2. Виконуємо нормування базового рядка до одиничного радіуса:

$$XB_j^{(k)'} = \frac{xB_j^{(k)'}}{D^{(k)'}} \text{ для } j = \overline{1, N}, \text{ де } D^{(k)'} - \text{відстань від початку координат до базової}$$

точки.

3. Обчислюємо коефіцієнт  $z_j^{(k)'}$  – відстань від  $i$ -ї точки до нормальної гіперплощини на  $k$ -му кроці ортогональних перетворень:

$$z_j^{(k)' } = \frac{1}{D^{(k)'}} \sum_{j=1}^n \left( x1_{i,j}^{(k)' } \times xB_j^{(k)' } \right).$$

4. Виконуємо  $k$ -й крок ортогональних перетворень, тобто проектуємо усі точки матриці реалізацій на нормальну гіперплощину вимірності  $N-1$ :  $x_{i,j}^{(k+1)' } = x_{i,j}^{(k)' } - XB_j^{(k)' } \times z_i^{(k)'}$ , для  $i = \overline{1, M}$ ,  $j = \overline{1, N}$ .

5. У пам'яті комп'ютера для подальшого застосування запам'ятовуємо величини:

- $xc'_j$  – центр ваги векторів-рядків початкової матриці кластера, для  $i = \overline{1, M}$ ,  $j = \overline{1, N}$ .

- $xB_j^{(k)'}$  та  $D^{(k)'}$  для  $k = \overline{1, k_{\max}}$ .

Виділення головних компонент біжучого зображення здійснюється за допомогою співвідношення:

$$z_i^{(k)} = \frac{1}{D^{(k)'}} \sum_{j=1}^n \left( x1_{i,j}^{(k)} \times xB_j^{(k)' } \right), \quad (1.3.2)$$

де  $x1_{i,j}^{(k)}$  – елементи центрованої матриці тестового зображення.

Відновлення первинного зображення здійснюється за таким алгоритмом:

1. Приймаємо  $x1_{i,j}^{(k_{\max}+1)} = 0$ , для  $i = \overline{1, M}$ ,  $j = \overline{1, N}$ .

2. Відновлюємо центровану матрицю  $x1_{i,j}^{(k)}$ . Для  $k = k_{\max}$  кроки зворотних перетворень здійснюються послідовно, починаючи від кроку  $k-1$  до 0; для  $i=1$  – крок від 1 до  $M$ ; для  $j=1$  – крок від 1 до  $N$  виконуємо:

$$x1_{i,j}^{(k)} = x1_{i,j}^{(k+1)} + XB_{i,j}^{(k)' } \times z_i^{(k)}.$$

3. Після цього відновлюємо початковий масив даних  $x_{i,j}$ . Для  $i=1$  – крок від 1 до  $M$ ; для  $j=1$  – крок від 1 до  $N$  виконуємо:  $x_{i,j} = x1_{i,j}^{(0)} + xc'_j$ .

Унаслідок архів збережених даних містить масив виділених головних компонент  $z_j^{(k)}$ , та масив параметрів нейромережі, тобто елементи базових рядків та параметрів структури.

Ще одним методом нейромережевого стиснення інформації є самоорганізована мережа Кохонена, яка розділяє вхідний простір на кластери, всередині яких дані мають квазіподібні ознаки. Таким чином, можна подати кожний з вхідних образів, що відносяться до одного кластера еталонним способом, яким є вектор ваг нейрона переможця, а потім номером еталонного образу. Якщо кількість нейронів у мережі значно менша за кількість варіантів вхідних образів, то для кодування еталонних кластерів необхідно мати значно менший обсяг інформації, ніж для кодування всіх вхідних векторів-образів. Відновлення стисненої інформації здійснюється на основі матриці ваг нейронів та номерів нейронів-переможців, які відповідають вхідним образам.

Якщо кількість нейронів у мережі зменшується, тоді об'єм пам'яті, який необхідний для зберігання матриці ваг нейронів та номерів нейронів переможців для кожного образу зменшується і відповідно коефіцієнт стиску збільшується, однак помилка подання кожного вхідного вектора також збільшується. Це в свою чергу приводить до зниження якості відновлення вхідних образів. Таким чином, змінюючи кількість нейронів у мережі, можна регулювати коефіцієнт стиснення і якість відновлення стисненої інформації.

Механізм стиснення інформації полягає у розбитті вхідного зображення на блоки розміром  $n \times t$ . Кожний блок записують у вигляді вхідного вектора, що містить  $3nt$  компонент розміром 1 байт (по 3 байти для кожного пікселя, що відображає червону, зелену та синю компоненти). Отриману вибірку використовують для навчання нейромережі Кохонена, що складається з  $N$  нейронів. Після заміни кожного з векторів вибірки на номер нейрона-переможця, ваги нейронів мережі, а також номери нейронів-переможців для кожного блоку зберігаються у файлі. Для відновлення зображення кожен номер нейрона-переможця замінюється на відповідний йому вектор ваг, тим самим забезпечуючи

одержання інформації про кольори кожного пікселя в блоці, з деякими спотвореннями.

Незважаючи на наявність різних алгоритмів компресії/декомпресії вхідних образів задача стиснення залишається актуальною, оскільки ці методи мають ряд недоліків.

Недоліки сучасних нейромережових методів і алгоритмів (RLE, LZW, Хаффмана, JBIG, Lossless JPEG, JPEG, Фрактальний) стиснення даних:

- До недоліків та обмежень існуючих нейромережових методів стиску відносять як можливість здійснення стиску вхідних образів лише з втратами інформації, так і грубе регулювання порогу втрат шляхом відкидання нейронів прихованого шару та значні часові затримки на виконання процедури навчання мережі.

- Недоліком алгоритму RLE є стиск зображення з плавною зміною кольору призводить до збільшення розміру файлу.

- Недоліком алгоритму LZW є менший коефіцієнт компресії порівняно зі схемою двоступеневого кодування.

- Недоліком алгоритму Хаффмана є залежність ступеня стиску від близькості ймовірностей символів до величини  $2^{-m}$ .

- Недоліком алгоритму JBIG є зниження ступеня стиску при підвищенні рівня шумів початкового зображення.

- Недоліком алгоритму Lossless JPEG є малий коефіцієнт стиску (при стиску зображення без втрат).

- Недоліком алгоритму JPEG є ефект Гібса. Відсутність автоматичного перетворення для множини випадків.

- Недоліком фрактального алгоритму є залежність результатів від принципів обробки базових елементів, коефіцієнт стиску залежить від повторюваності базових елементів.

#### 1.4. Аналіз технологій нейронних мереж в задачах шифрування інформації

Починаючи з 2000-х років розроблено багато криптосистем, для яких доведено, що їх стійкість еквівалентна складності розв'язку окремих складних задач, наприклад, задач розкладу цілих чисел, факторизації, дискретного логарифмування [85 – 92].

Криптоаналіз існуючих криптоалгоритмів є актуальним, оскільки заздалегідь можна розпізнати нестійкість криптоалгоритму та покращити його або замінити новим. Сучасне програмне забезпечення широко використовує криптоалгоритми не тільки для задач шифрування даних, але і для аутентифікації та перевірки цілісності.

«Класичний» криптоаналіз розглядає алгоритми шифрування тільки з погляду математичного, оперуючи алгебраїчними властивостями та параметризованим ключем, тоді як криптоаналіз побічних каналів розглядає такі параметри як час виконання операцій, споживану потужність, спектр електромагнітного та акустичного випромінювання.

У роботі [93] показано, що алгоритми DES та AES схильні до атак на побічні канали. Відповідно до теореми Хехт-Нільсена [94], нейронною мережею можна представити абсолютно довільну функцію з  $n$  змінними, в тому числі і криптографічну. Апроксимуючи алгоритм AES нейронною мережею [5] можна значно підвищити його стійкість до атак по побічним каналам. Нейромережа забезпечує більший ступінь захищеності від атак на побічні канали, оскільки:

1. Кожен нейрон містить незначну кількість інформації, яка необхідна для точної роботи алгоритму.
2. Обчислення здійснюються для кожного нейрона незалежно від вхідних даних.
3. Важливою властивістю мережі є те, що за її вагами складно визначити, яким був секретний ключ, а в окремих випадках – алгоритм шифрування.

Основою алгоритму шифрування AES може бути багатошаровий перцептрон прямого поширення. Алгоритм шифрування складається з таких

етапів: попередня обробка даних, формування навчальної вибірки; вибір топології нейронної мережі; процес навчання нейронної мережі; процес шифрування відкритого тексту у зашифрований; процес дешифрування зашифрованого тексту у відкритий.

Вхідні дані нормалізуються за допомогою коефіцієнта масштабування. При розв'язку цієї задачі автор [5] використовує нейронну мережу, що складається з 4-х шарів (Рис. 1.4.1).




Рис. 1.4.1. Архітектура нейронної мережі, що використовується для шифрування

У процесі навчання на вхід нейронній мережі поступає відкритий текст у вигляді блоків і обробляється у прихованих шарах нейронної мережі. На виході отриманий текст порівнюється з цільовим виходом нейронної мережі і якщо необхідно, то нейронна мережа навчається для досягнення потрібного

зашифрованого тексту. Отримані кінцеві ваги використовуються для шифрування і дешифрування повідомлення.

$$output = \tanh \left( \sum_{k=1}^{16} W_{1k} \cdot \tanh \left( \sum_{k=1}^{16} \sum_{j=1}^{16} W_{kj} \cdot \tanh \left( \sum_{j=1}^{16} \sum_{i=1}^4 W_{ji} \cdot \tanh \left( \sum_{i=1}^4 W_{i1} \cdot input \right) \right) \right) \right), \quad (1.4.1)$$

де *output* – зашифрований текст, *W* – ключ у вигляді матриці, *input* – відкритий текст.

Така криптосистема на основі нейронної мережі є більш стійкою до відомих атак на побічні канали алгоритму AES. Проте після навчання нейронної мережі можливі помилкові відхилення значень від значень шифрування або дешифрування, що приведе до спотворень у тексті. Недоліками даного підходу також є використання симетричного ключа та кодування інформації одним ключем, що робить систему більш вразливою при великому об'ємі повідомлень.



## Висновки до розділу 1

У першому розділі дисертації здійснено системний аналіз наукової літератури щодо теми дисертаційного дослідження та сформульовано такі нерозв'язані проблеми:

- збільшення коефіцієнту стиску інформації при стисненні даних без втрат внаслідок діагоналізації матриці вагових синаптичних зв'язків між нейронами;
- зменшення обчислювального ресурсу і часу налаштування синаптичних зв'язків під час навчання нейронної мережі;
- зменшення числа операцій агрегування при апроксимації функції багатьох змінних багатошаровою нейронною мережею;
- оптимізація структури багатошарової нейронної мережі в межах нелінійної моделі узагальненої похибки;
- підвищення ступеня криптостійкості нейромереж внаслідок створення постійно змінного ключа шифрування;
- врахування числа імпульсів сигналу, які подаються на вхід нейронів та часу релаксації нейрона після потенціалу його дії;
- розпізнавання мультиспектральних образів осциляторною нейронною мережею на основі інформаційного резонансу з амплітудою сигналу, співмірною рівню шуму.

## РОЗДІЛ 2. СТИСК ТА ШИФРУВАННЯ ВХІДНИХ ОБРАЗІВ МЕТОДОМ ДІАГОНАЛІЗАЦІЇ МАТРИЦІ ВАГОВИХ СИНАПТИЧНИХ ЗВ'ЯЗКІВ У НЕЙРОННІЙ МЕРЕЖІ

### 2.1. Стиск вхідних образів на основі методу діагоналізації матриці вагових синаптичних зв'язків

Незважаючи на наявність різних алгоритмів компресії/декомпресії вхідних образів з появою нових технічних засобів питання стиску зображень залишається актуальним, оскільки ці засоби дозволяють оцінити можливості вже існуючого математичного апарату, що використовується для стиску зображень [95 – 101].

Коефіцієнт стиснення інформації  $K$  нейронною мережею розраховується за формулою

$$K = \frac{N_I \cdot I_I}{N_N \cdot I_I + N_I \cdot I_N}, \quad (2.1.1)$$

де  $N_I$  – кількість вхідних образів;  $N_N$  – кількість нейронів у мережі;  $I_I$  – об'єм пам'яті, необхідний для зберігання одного образу або вектора ваг нейрона;  $I_N$  – об'єм пам'яті, необхідний для зберігання номера нейрона.

Формулу (2.1.1) можна виразити через число синаптичних зв'язків  $N_\lambda$

$$K = \frac{\frac{N_I^2}{N_\lambda} I_I}{I_I + \frac{N_I^2}{N_\lambda} I_N}, \quad (2.1.2)$$

Як показує аналіз формули (2.1.2), якщо  $N_\lambda \rightarrow 0$ , то  $K \rightarrow \frac{I_I}{I_N}$ , а якщо  $N_\lambda \rightarrow \infty$ , то  $K \rightarrow 0$ . Таким чином, для збільшення коефіцієнту стиску необхідно зменшувати число синаптичних зв'язків нейронної мережі. Для збільшення коефіцієнту стиску завдяки зменшенню числа синаптичних зв'язків між нейронами пропонується спосіб стиску вхідного інформаційного сигналу у нейронній мережі внаслідок діагоналізації матриці  $\hat{\lambda} \equiv (\lambda_{ik})$  вагових коефіцієнтів синаптичних зв'язків між нейронами.

Оскільки природа синаптичних зв'язків між біологічними нейронами є квантово-статистичною [102, 103], у цій задачі розглядаємо синаптичні зв'язки між  $i$ -м і  $k$ -м нейронами  $\lambda_{ik}$ , які мають статистичний характер і не залежать від тих зв'язків, що є між іншими нейронами  $\lambda_{\alpha\beta}$ . У цьому випадку статистичні властивості  $\lambda_{ik}$  цілком визначаються функцією розподілу  $f(\lambda_{ik})$  на зв'язку між  $i$ -м і  $k$ -м нейронами. Припустимо, що  $f(\lambda_{ik})$  є гаусова функція розподілу

$$f(\lambda_{ik}) = \frac{1}{\tilde{\lambda}_{ik} \sqrt{2\pi}} \exp\left(-\frac{\lambda_{ik}^2}{2\tilde{\lambda}_{ik}^2}\right), \quad (2.1.3)$$

яка задається двома параметрами: середнім значенням  $\bar{\lambda}_{ik} = \langle \lambda_{ik} \rangle$  і дисперсією  $\tilde{\lambda}_{ik} = \langle \lambda_{ik}^2 \rangle - \langle \lambda_{ik} \rangle^2$ .

Нехай, ми хочемо запам'ятати прототип образу тришаровою нейронною мережею прямого поширення (Рис. 2.1.1). Цей образ описується детермінованим вектором

$$\vec{V} = (V_1, V_2, \dots, V_n), \quad (2.1.4)$$

де  $V_i = \vec{e}_i \vec{V}$  – проекція  $\vec{V}$  на  $\vec{e}_i$  ( $\vec{e}_i$  –  $i$ -й базисний вектор системи координат).

Для запам'ятовування прототипу образу (інформаційного сигналу) накладаємо на синаптичні зв'язки  $\lambda_{ik}$  (синаптичні зв'язки від джерел  $V_1, V_2, \dots, V_n$  до нейронів  $1, 2, 3, \dots, N$ ) обмеження

$$\lambda_{ik} = V_i \cdot V_k, \quad \lambda_{ik} \neq \lambda_{ki} \text{ при } i \neq k \quad (2.1.5)$$

і сформуємо матрицю  $\hat{\lambda}$  з детермінованими матричними елементами

$$\langle \lambda_{ik} \rangle = \langle V_i \rangle \cdot \langle V_k \rangle \quad (2.1.6)$$

та приведемо її до діагонального виду з дійсними власними значеннями

$$\beta_k = \beta_i \delta_{ik}. \quad (2.1.7)$$

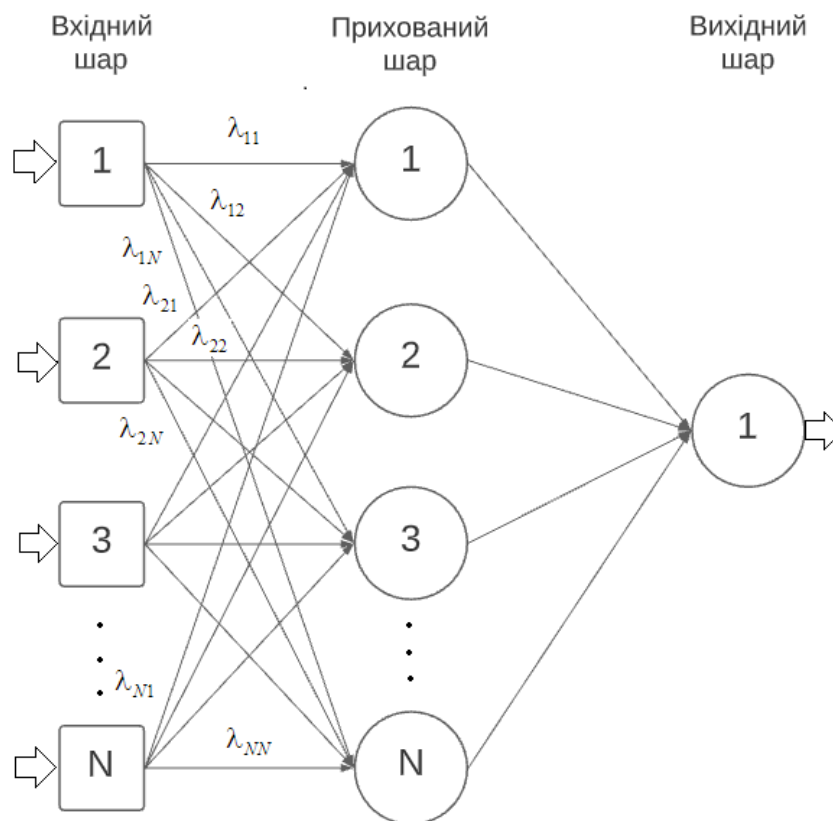


Рис. 2.1.1. Структура нейронної мережі прямого поширення з діагональними та недіагональними ваговими коефіцієнтами синаптичних зв'язків  $\lambda_{ik}$ .

Для приведення матриці  $\hat{\lambda}$  до діагонального вигляду зведемо її до симетричної форми та зробимо лінійне перетворення

$$\hat{\lambda} = \hat{U}^{-1} \hat{\lambda} \hat{U}, \quad (2.1.8)$$

де  $\hat{U}$  – матриця складається з власних базисних векторів  $\vec{u}_k$  матриці  $\hat{\lambda}$ , тобто  $\hat{U} = (\vec{u}_1, \vec{u}_2, \dots, \vec{u}_k, \dots, \vec{u}_n)$ ;

$$\hat{\lambda} \vec{u}_k = \beta_k \vec{u}_k. \quad (2.1.9)$$

У базисі з власних векторів  $\vec{u}_k$  матриця лінійного перетворення  $\hat{\lambda}$  має діагональний вигляд, причому на головній діагоналі розташовані дійсні власні числа  $\beta_k \equiv \tilde{\lambda}_{ik} = \beta_i \delta_{ik}$  матриці  $\hat{\lambda}$ . Необхідно зазначити, що  $\tilde{\lambda}_{ik} = f(\lambda_{ik})$ .

Для запам'ятовування  $N$  різних образів-еталонів ( $N$  різних прототипів-образів) коефіцієнти синаптичних зв'язків  $\lambda_{ik}$  вибираємо у вигляді:

$$\lambda_{ik} = \sum_{n=1}^N V_i^{(n)} \cdot V_k^{(n)}. \quad (2.1.10)$$

Алгоритм приведення  $\lambda_{ik}$  (2.1.10) до діагонального вигляду аналогічний (2.1.5).

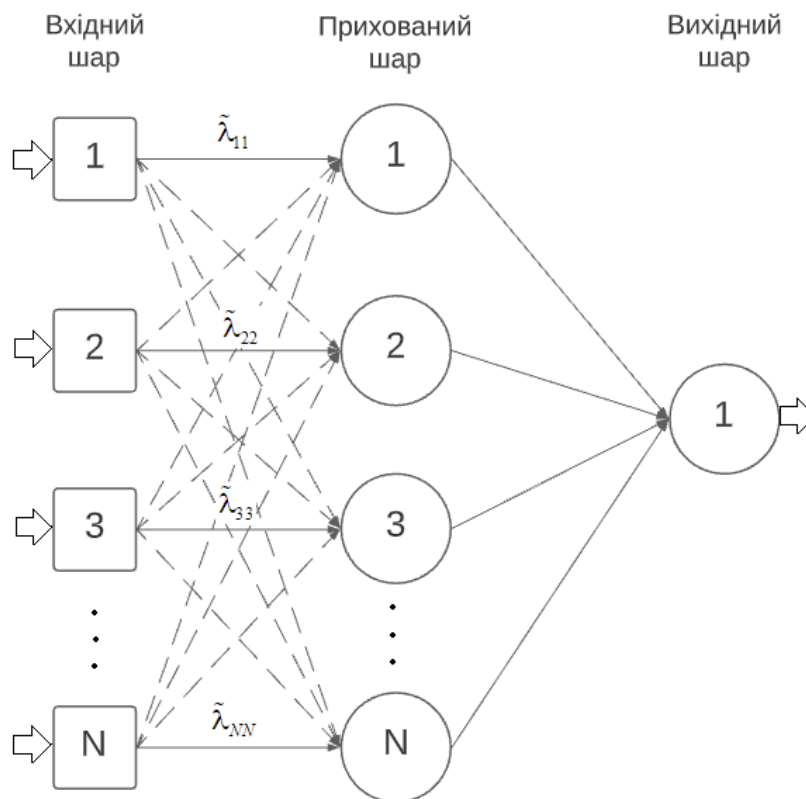


Рис. 2.1.2. Структура нейронної мережі прямого поширення після діагоналізації матриці вагових коефіцієнтів синаптичних зв'язків  $\lambda_{ik}$ .

Порівняльний аналіз схематичних зображень нейронних мереж (Рис. 2.1.1, Рис. 2.1.2) показує, що до діагоналізації матриці вагових синаптичних зв'язків їх число було  $N_\lambda = N_I \cdot N_N$  ( $N_I$  – кількість нейронів у першому шарі нейронної мережі,  $N_N$  – кількість нейронів у прихованому шарі нейронної мережі), якщо  $N_I = N_N$ , то  $N_\lambda = N_I^2 = N_N^2$ , тоді після діагоналізації число синаптичних зв'язків стало  $\tilde{N}_\lambda = N_I = N_N$ . Необхідно зауважити, що недіагональні компоненти синаптичних зв'язків не зникають, а містяться в перенормованих елементах головної діагоналі після діагоналізації. Після діагоналізації матриці синаптичних зв'язків вираз для коефіцієнта стиску матиме вигляд:

$$\tilde{K} = \frac{\frac{N_I^2}{\tilde{N}_\lambda} \cdot I_I}{I_I + \frac{N_I^2}{\tilde{N}_\lambda} \cdot I_N}, \quad (2.1.11)$$

де  $\tilde{N}_\lambda$  – число зв'язків після діагоналізації нейронної мережі.

Таким чином, після діагоналізації синаптичних [104 – 106] зв'язків між першим (сенсорним) і другим (прихованим) шарами відношення коефіцієнту стиску  $\tilde{K}$  діагоналізованої тришарової нейронної мережі до коефіцієнту стиску  $K$  недіагоналізованої тришарової нейронної мережі буде визначатися:

$$\frac{\tilde{K}}{K} = \frac{\tilde{N}_\lambda \left( I_I + \frac{N_I^2}{\tilde{N}_\lambda^2} I_N \right)}{\left( I_I + \frac{N_I^2}{\tilde{N}_\lambda} I_N \right)}, \quad (2.1.12)$$

за умови  $I_I = I_N$  відношення

$$\frac{\tilde{K}}{K} = \frac{2N_I}{N_I + 1} = \frac{2N_N}{N_N + 1} = \frac{2\tilde{N}_\lambda}{\tilde{N}_\lambda + 1}, \quad (2.1.14)$$

або

$$\frac{\tilde{K}}{K} = O\left(\frac{2N_N}{N_N + 1}\right), \quad (2.1.15)$$

де значення в дужках визначає порядок величини.

Аналіз співвідношення (2.1.12) показує, якщо  $N_N \gg 1$ , тоді відношення  $\frac{\tilde{K}}{K} \rightarrow 2$ .

Тобто, зменшення числа вагових коефіцієнтів синаптичних зв'язків приводить до ущільнення інформації, яка подається від вхідних образів до нейронної мережі по каналах головних елементів  $\tilde{\lambda}_{ii}$  ( $i = 1, 2, \dots, N$ ) матриці синаптичних зв'язків між нейронами.

Операція діагоналізації приводить до спрощеного налаштування вагових коефіцієнтів синаптичних зв'язків у нейронній мережі в процесі її навчання

завдяки зміні конфігурації мережі (Рис. 2.1.2) та до зменшення числа операцій агрегування.

Формула (2.1.16) показує, у скільки разів час налаштування повнозв'язної мережі більший від часу налаштування діагоналізованої при умові, що кількість нейронів у першому і другому шарах є рівною, а між другим і третім – різною.

$$\frac{t_{full}}{t_{diag}} = \frac{k_1 N_\lambda + k_2 N_2}{k_1 \tilde{N}_\lambda + k_2 N_2} = \frac{k_1 N_\lambda + k_2 N_2}{k_1 \sqrt{N_\lambda} + k_2 N_2}, \quad (2.1.16)$$

де  $k_1$  – час налаштування одного зв'язку між першим і другим шаром нейронів,  $k_2$  – час налаштування одного зв'язку між другим і третім шаром нейронів,  $N_\lambda$  – кількість зв'язків між першим і другим шаром нейронів до діагоналізації,  $\tilde{N}_\lambda$  – кількість зв'язків між першим і другим шаром нейронів після діагоналізації,  $N_2$  – кількість зв'язків між другим і третім шаром нейронів.

Для прикладу розглянемо машину Больцмана (нейронна мережа, яка створена на основі навчання Больцмана) до діагоналізації матриці вагових коефіцієнтів синаптичних зв'язків  $\lambda_{ik}$ . Ця нейронна мережа характеризується функцією енергії  $E$ , значення якої визначається станами окремих нейронів, з яких складається ця мережа. Функція  $E$  визначається [107, 108]:

$$E = -\frac{1}{2} \sum_i \sum_{k(i \neq k)} \lambda_{ik} Y_k X_i, \quad (2.1.17)$$

де  $X_i$ ,  $Y_k$  – стани  $i$ -го та  $k$ -го нейронів;  $\lambda_{ik}$  – вага синаптичного зв'язку між  $i$ -им та  $k$ -им нейронами. Умова  $i \neq k$  підкреслює той факт, що в цій мережі нейрони не мають зворотних зв'язків із самими собою.

Після операції діагоналізації вагових коефіцієнтів синаптичних зв'язків  $\lambda_{ik} \rightarrow \tilde{\lambda}_{ik} = \beta_i \delta_{ik}$  функція енергії набуває вигляду:

$$E = -\frac{1}{2} \sum_i \beta_i Y_i X_i. \quad (2.1.18)$$

Як видно із співвідношення (2.1.18), діагоналізація матриці синаптичних зв'язків привела до зменшення їх числа (стиску вхідних образів), оскільки залишилися тільки діагональні елементи  $\beta_i$ , які містять інформацію про вектор

вхідних сигналів (образів) і безпосередньо використовуються для процесу навчання нейронної мережі.

## 2.2. Модифікована теорема Хехт-Нільсена для нейронної мережі з діагоналізованими синаптичними зв'язками

Для знаходження прихованих взаємозв'язків між елементами різних множин і встановлення закономірностей між ними виникає необхідність у представленні функцій  $n$  змінних у вигляді суперпозиції функцій від меншого числа змінних.

Математичним обґрунтуванням використання штучної нейронної мережі для апроксимації функції багатьох змінних через лінійну комбінацію функцій однієї змінної є теорема А.Н. Колмогорова, яка твердить про представлення неперервної функції  $n$  змінних у вигляді суперпозиції  $m$  неперервних функцій однієї змінної.

Хехт-Нільсен [94] показав, що неперервна функція багатьох змінних може бути представлена за допомогою тришарової нейронної мережі з  $n$  компонентами вхідного сигналу,  $2n + 1$  компонентами прихованого шару з сигмоїдними функціями активації і  $M$  компонентами вихідного шару з невідомими функціями активації та двома операціями агрегації. Таким чином, у неконструктивній формі був доведений розв'язок задачі представлення функції від  $n$  змінних за допомогою нейронної мережі.

У роботі [109] показано, що в інтегральній метриці з вагою Чебішева-Ерміта, можливе наближення функції  $n$  змінних тришаровою нейронною мережею, причому функції активації прихованого шару можуть бути задані заздалегідь, а вихідного – лінійні.

У дисертаційній роботі пропонується модифікована тришарова нейронна мережа з архітектурою, яка має тільки діагональні синаптичні зв'язки між нейронами [104, 110], внаслідок чого отримуємо модифіковану теорему Хехт-Нільсена. Така архітектура тришарової нейронної мережі ( $m = 2n + 1$  – кількість нейронів прихованого шару нейромережі;  $n$  – число вхідних образів) дає змогу



апроксимувати функцію від  $n$  змінних, з заданою точністю  $\varepsilon > 0$ , за допомогою однієї операції агрегування. Тоді як тришарова нейронна мережа, яка має як діагональні, так і не діагональні синаптичні зв'язки між нейронами, апроксимує функцію від  $n$  змінних за допомогою двох операцій агрегування. Крім цього, діагоналізація матриці синаптичних зв'язків приводить до зменшення використовуваного обчислювального ресурсу і відповідно до зменшення часу налаштування вагових коефіцієнтів синаптичних зв'язків під час навчання нейронної мережі.

Для штучної нейронної мережі з діагональними та недиагональними синаптичними зв'язками між нейронами ця теорема була сформульована Хехт-Нільсеном [94]: для довільного  $\varepsilon > 0$  існує тришарова нейронна мережа, вихідні функції якої для прихованого шару є  $g_j(\vec{V})$ , а вихідні функції (функції активації) для вхідних і вихідних шарів є лінійними і мають функцію вводу-виводу

$$F_\varepsilon(V_1, V_2, \dots, V_n) = \sum_{j=1}^m W_j \cdot g_j \left[ \sum_{i=1}^n \lambda_{ij}(V_i) \right], \quad (2.2.1)$$

таку що

$$\max_{V \in K} |F(V_1, V_2, \dots, V_n) - F_\varepsilon(V_1, V_2, \dots, V_n)| < \varepsilon, \quad (2.2.2)$$

де  $K$  – компактна підмножина (обмежена замкнута підмножина)  $R^n$ , а

$F(V_1, V_2, \dots, V_n)$  – дійсна неперервна функція на  $K$ . Тобто, будь яку неперервну функцію  $F(\vec{V})$  від  $n$  змінних  $\vec{V} = (V_1, V_2, \dots, V_n)$  можна з заданою точністю  $\varepsilon > 0$

апроксимувати за допомогою тришарової нейронної мережі з одним прихованим шаром, яка описується рівнянням

$$F_\varepsilon(V_1, V_2, \dots, V_n) = \sum_{j=1}^m W_j \cdot g_j \left[ \sum_{i=1}^n \lambda_{ij}(V_i) \right],$$

для чого

достатньо підібрати  $m = 2n + 1$  передавальних функцій  $\lambda_{ij}(V_i)$  нейронів прихованого шару ( $m$  – кількість нейронів прихованого шару нейронної мережі);

де  $\lambda_{ij}(V_i)$  – сенсорні функції, а  $g_j$  – функції активації нейронів прихованого шару.

Як видно з формулювання теорема для апроксимації функції  $F(\vec{V})$  від  $n$  змінних

$\vec{V} = (V_1, V_2, \dots, V_n)$  тришаровою нейронною мережею використовуються дві операції агрегування  $\sum_{j=1}^m \dots \cdot \sum_{i=1}^n \dots$

Сформулюємо теорему Хехт-Нільсена для модифікованої тришарової штучної нейронної мережі з діагональними синаптичними зв'язками між нейронами.

**Твердження.** Для довільного  $\varepsilon > 0$  існує тришарова нейронна мережа, вихідні функції якої для прихованого шару є  $g_j(\vec{V})$ , а вихідні функції (функції активації) для вхідних і вихідних шарів є нелінійними і мають функцію вводу-виводу

$$\tilde{F}_\varepsilon(V_1, V_2, \dots, V_n) = \sum_{j=1}^m W_j \cdot g_j \left[ \sum_{i=1}^n \lambda_{ij}(V_i) \right], \quad (2.2.3)$$

таку що

$$\max_{V \in K} |F(V_1, V_2, \dots, V_n) - \tilde{F}_\varepsilon(V_1, V_2, \dots, V_n)| < \varepsilon, \quad (2.2.4)$$

де  $K$  – компактна підмножина (обмежена замкнута підмножина)  $R^n$ , а  $F(V_1, V_2, \dots, V_n)$  – дійсна неперервна функція на  $K$ . Тобто, будь яку неперервну функцію  $\tilde{F}(\vec{V})$  від  $n$  змінних  $\vec{V} = (V_1, V_2, \dots, V_n)$  можна з заданою точністю  $\varepsilon > 0$  апроксимувати за допомогою тришарової нейронної мережі з одним прихованим шаром та однією операцією агрегування, для чого достатньо діагоналізувати матрицю синаптичних зв'язків між вектором вхідних сигналів та прихованим шаром нелінійних нейронів і підібрати  $m = 2n + 1$  передавальних функцій  $\tilde{\lambda}_{ij}(V_i)$  нейронів прихованого шару.

$$\tilde{F}_\varepsilon(V_1, V_2, \dots, V_n) = \sum_{j=1}^m W_j \cdot g_j [\beta_j V_j + \theta_j], \quad (2.2.5)$$

де  $g_j[\beta_j V_j + \theta_j]$  – функція активації  $j$ -го нейрона прихованого шару;

$W_j$  – вагові коефіцієнти синаптичних зв'язків від прихованого шару до виходу;

$\theta_j$  – адитивна складова вхідного сигналу (порог збудження нейрона).

**Доведення.** Нехай дано архітектуру класичної штучної тришарової нейронної мережі (з одним прихованим шаром), за допомогою якої (згідно теореми Хехт-Нільсена [94]), можна з заданою точністю  $\varepsilon > 0$  апроксимувати неперервну функцію  $F$  від  $n$  змінних  $\vec{V} = (V_1, V_2, \dots, V_n)$ , для чого достатньо підібрати  $m = 2n + 1$  передавальних функцій  $\lambda_{ij}(V_i)$  нейронів прихованого шару, тобто

$$F(V_1, V_2, \dots, V_n) = \sum_{j=1}^m W_j \cdot g_j \left[ \sum_{i=1}^n \lambda_{ij}(V_i) \right], \quad (2.2.6)$$

де  $\lambda_{ij}(V_i)$  – сенсорні функції, які встановлюють функціональну залежність між вхідним сигналом  $V_i$  та ваговими коефіцієнтами синаптичних зв'язків  $\lambda_{ij}$  з нейронами прихованого шару.

$$\lambda_{ij}(V_i) \equiv \lambda_{ij} \cdot V_i + \theta_j, \quad (2.2.7)$$

де  $\lambda_{ij}$  – вагові коефіцієнти синаптичних зв'язків від входу до прихованого шару.

Для отримання архітектури модифікованої штучної нейронної мережі з нелінійними нейронами із архітектури класичної тришарової нейромережі необхідно діагоналізувати матрицю синаптичних зв'язків  $\hat{\lambda}_{ij}$  між вхідними образами  $\vec{V} = (V_1, V_2, \dots, V_n)$  та прихованим шаром.

Операція діагоналізації матриці синаптичних зв'язків здійснюється на основі співвідношень (2.1.5) – (2.1.9).

Після діагоналізації отримаємо модифіковану теорему Хехт-Нільсена (2.2.5), яка описує архітектуру штучної нейронної тришарової мережі з діагональними синаптичними зв'язками та з однією операцією агрегування.

**Твердження доведено.**

Необхідно зауважити, що діагоналізація матриці синаптичних зв'язків приводить до зменшення операцій агрегування  $\left( \mathbf{A} = \sum_{j=1}^m \text{and/or} \prod_{j=1}^m \dots \right)$ , що в свою чергу приводить до зменшення обчислювального ресурсу і до зменшення часу

налаштування вагових коефіцієнтів синаптичних зв'язків у нейронній мережі в процесі її навчання завдяки зміні конфігурації мережі.

### 2.3. Нелінійна модель оптимізації розміру багат шарової нейронної мережі в межах узагальненої похибки

У цьому параграфі представлено спосіб оптимізації структури багат шарової нейронної мережі на основі мінімізації нелінійної узагальненої похибки, яка базується на принципі мінімальної довжини опису. Згідно з цим принципом, узагальнена похибка мережі при роботі з новими даними визначається похибкою апроксимації даних нейронною мережею в нелінійному наближенні та похибкою опису моделі. З умови мінімуму узагальненої похибки мережі виведені вирази для обчислення оптимального розміру мережі (кількість синаптичних зв'язків та кількість нейронів у прихованих шарах).

При моделюванні нейронної мережі число її параметрів, як правило, є великим, зокрема, розмір мережі ( $N_{\lambda_{ij}}$  – загальне число синаптичних зв'язків, індекс  $\lambda_{ij}$  – описує значення синаптичних зв'язків між  $i$ -им та  $j$ -им нейронами;  $n_k$  – число нейронів у прихованих шарах) співвідноситься з розміром навчальної вибірки  $N_p$  ( $N_{\lambda_{ij}} \leq N_p$ ), тобто число параметрів залежить від числа навчальних даних і числа вхідних образів  $N_{in}$ .

Одним з головних критеріїв ефективності функціонування багат шарової нейронної мережі є узагальнена похибка  $\varepsilon$  [6, 111, 112]. За допомогою цієї похибки можна оцінити точність нейронної мережі, що здатна класифікувати дані, які не були представлені у навчальній вибірці. Оптимізацію узагальненої похибки, яка складається із суми похибки апроксимації  $\varepsilon_a$  (емпірична похибка) та похибки, пов'язаної зі складністю моделі  $\varepsilon_m$  (морфологією моделі нейронної мережі), визначає принцип мінімальної довжини опису [111].

$$\min_{N_{\lambda_{ij}}} \left\{ -\ln P\left(N_p \mid \left(N_{\lambda_{ij}}; \lambda_{ij}\right)\right) - \ln P\left(N_{\lambda_{ij}}; \lambda_{ij}\right) \right\} = \min_{N_{\lambda_{ij}}} \{ \varepsilon_a + \varepsilon_m \}, \quad (2.3.1)$$

де перший доданок описує похибку апроксимації (умовна ймовірність). Чим менша похибка апроксимації, тим менше біт інформації необхідно для виправлення передбачень моделі. Зокрема, в задачі апроксимації функції припускається, що множина взаємопов'язаних даних  $\{\bar{x}_\alpha, \bar{y}_\alpha\}$  описується деякою невідомою функцією, яку і потрібно встановити, але їх істинні значення спотворені випадковим гаусівським шумом. Таким чином, умовна ймовірність множини даних  $\{\bar{x}_\alpha, \bar{y}_\alpha\}$  для моделі нейронної мережі  $\{\bar{y}(\bar{x}_\alpha; N_{\lambda_{ij}}; n_k; \lambda_{ij})\}$ , яка залежить від параметрів  $N_{\lambda_{ij}}$ ,  $n_k$ ,  $\lambda_{ij}$ , що настроюються, має гаусівський розподіл:

$$P(y_\alpha | (N_{\lambda_{ij}}; \lambda_{ij})) \propto \exp \left[ \frac{-\left(y_\alpha - y(\bar{x}_\alpha; N_{\lambda_{ij}}; n_k; \lambda_{ij})\right)^2}{2\sigma^2} \right], \quad (2.3.2)$$

де  $\sigma^2$  – дисперсія. Необхідно зазначити, що правильна апроксимація зашумленої функції  $\{\bar{y}(\bar{x}_\alpha; N_{\lambda_{ij}}; n_k; \lambda_{ij})\}$  повинна давати похибку порядку дисперсії шуму. Тоді з врахуванням (2.3.2) похибка апроксимації  $P(N_p | (N_{\lambda_{ij}}; \lambda_{ij}))$  рівна:

$$P(N_p | (N_{\lambda_{ij}}; \lambda_{ij})) = \sum_{\alpha=1}^{N_p} P(y_\alpha | (N_{\lambda_{ij}}; \lambda_{ij})). \quad (2.3.3)$$

Згідно з принципом мінімальної довжини опису (2.3.1) можна мінімізувати загальну довжину опису даних на основі апроксимації функції нейронною мережею та опису самої моделі. Якщо модель передбачає всі дані точно, то довжина опису похибки дорівнює нулю. Другий доданок у формулі (2.3.1) визначає зміст кількості інформації, необхідної для вибору конкретної моделі з множини з апіорним розподілом ймовірностей  $P(N_{\lambda_{ij}}; \lambda_{ij})$ .

Зокрема, в роботах [111, 113] похибки апроксимації та опису моделі описувались у лінійних наближеннях  $\varepsilon_a = o\left(\frac{N_{in}}{N_{\lambda_{ij}}}\right)$  та  $\varepsilon_m = o\left(\frac{N_{\lambda_{ij}}}{N_p}\right)$ ,

де  $N_{in}$  – кількість вхідних образів. У такому наближенні формула для узагальненої похибки  $\varepsilon$  нейронної мережі описувалась виразом

$$\varepsilon = \varepsilon_a + \varepsilon_m = \frac{N_{in}}{N_{\lambda_{ij}}} + \frac{N_{\lambda_{ij}}}{N_p}. \quad (2.3.4)$$

Необхідно зазначити, що складові  $\varepsilon_a$  і  $\varepsilon_m$  по різному залежать від розміру нейронної мережі (числа синаптичних зв'язків, числа нейронів), що припускає можливість вибору оптимального розміру нейронної мережі. Слід зауважити, що модель (2.3.4) добре описує нейронну мережу в наближеннях  $\frac{N_{in}}{N_{\lambda_{ij}}} \ll 1$  та  $\frac{N_{\lambda_{ij}}}{N_p} \ll 1$ .

У випадках, коли відношення числа вхідних образів до числа синаптичних зв'язків становить  $\frac{N_{in}}{N_{\lambda_{ij}}} < 1$  та відношення числа синаптичних зв'язків до числа

навчальних прикладів становить  $\frac{N_{\lambda_{ij}}}{N_p} \leq 1$  (випадок, коли число синаптичних

зв'язків є не більшим числа навчальних прикладів) модель узагальненої похибки (2.3.4) буде неточно описувати похибку  $\varepsilon$  нейронної мережі. При виконанні останніх умов похибку апроксимації  $\varepsilon_a$  необхідно описувати в наближенні

$\varepsilon_a = o\left(\frac{N_{in}}{N_{\lambda_{ij}}}\right)$ , а похибку опису моделі  $\varepsilon_m$  необхідно описувати в нелінійному

наближенні  $\varepsilon_m = o\left(\frac{N_{\lambda_{ij}}^2}{N_p^2}\right)$ .

$$\varepsilon_a = o\left(\frac{N_{in}}{N_{\lambda_{ij}}}\right); \varepsilon_m = o\left(\frac{N_{\lambda_{ij}}^2}{N_p^2}\right). \quad (2.3.5)$$

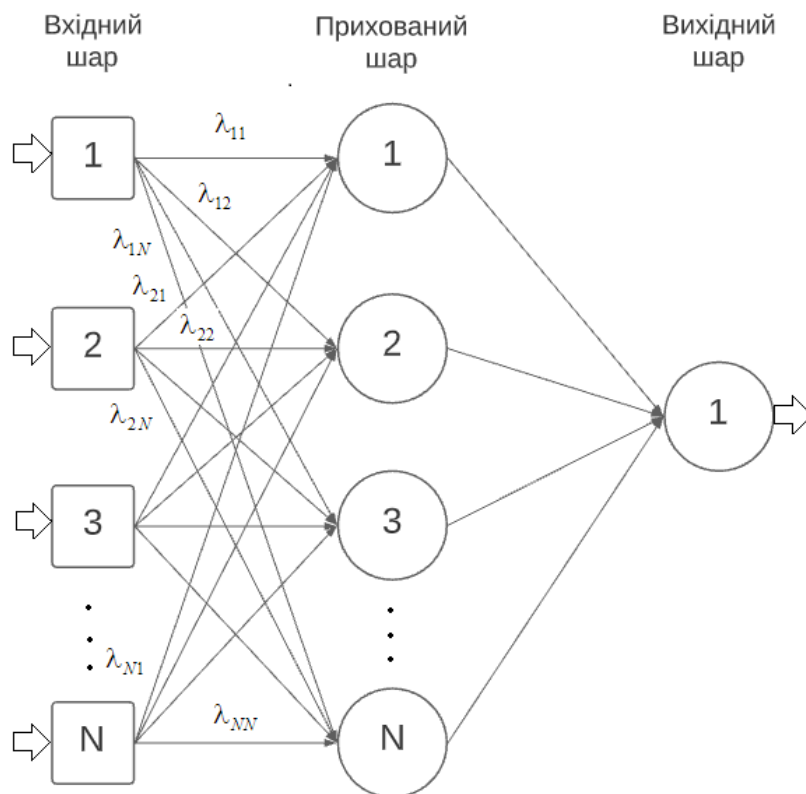


Рис. 2.3.1. Тришарова нейронна мережа

Іншою проблемою оптимізації багат шарової нейронної мережі (Рис. 2.3.1) є перенавчання. Нехай навчальна вибірка описується певною функцією, яку нам потрібно відтворити. При навчанні таку функцію називають вчителем. При обмеженому числі навчальних прикладів  $N_p$  можна побудувати нейронну мережу з мінімальною похибкою навчання, тобто похибкою, яка формується на множині навчальних прикладів. Для цього потрібно взяти нейронну мережу з кількістю синаптичних зв'язків ( $N_{\lambda_{ij}}$ , де  $\lambda_{ij}$  – синаптичні зв'язки між  $i$ -им та  $j$ -им нейронами) більшою, ніж кількість навчальних прикладів  $N_p$ , тобто ( $N_{\lambda_{ij}} > N_p$ ). Щоб відтворити кожен приклад, ми маємо  $N_p$  рівнянь для  $N_{\lambda_{ij}}$  невідомих. Відомо [114], коли число рівнянь  $N_p$  менше числа невідомих  $N_{\lambda_{ij}}$ , тоді така система є недовизначеною і допускає нескінченну множину розв'язків. Головна проблема у тому, що не вистачає інформації, щоб вибрати єдине правильне рішення – функцію-вчителя. Вибрана випадково функція дає неточності на нових прикладах,

які відсутні в навчальній вибірці, хоч і навчальну вибірку відтворює без похибок. Замість того, щоб узагальнити навчальну вибірку, мережа запам'ятала її. Цей ефект називається перенавчанням [111].

Насправді задачею навчання нейронної мережі є не мінімізація похибки навчання, а мінімізація похибки узагальнення  $\varepsilon$ , визначеної для всіх можливих прикладів у майбутньому. Мережа з мінімальною похибкою узагальнення  $\varepsilon_{\min}$  буде володіти максимальною точністю розпізнавання та класифікації образів.

За аналогією з біологічною нейронною мережею похибка апроксимації (навчання) співвідноситься з запам'ятовуванням навчальних даних багатошаровим перцептроном, а похибка опису моделі співвідноситься з узагальненням (стисненням) цих даних. Зазначимо, що запам'ятовування і стиснення навчальних даних відбувається внаслідок зміни вагових коефіцієнтів синаптичних зв'язків та зміни топології нейронів у нейронній мережі.

Задача мінімізації числа нейронів і синаптичних зв'язків у нейронних мережах прямого поширення була розглянута у роботі [115] в межах нелінійної моделі узагальненої похибки на основі метричних методів розпізнавання.

За критерій оптимізації загальної кількості синаптичних зв'язків  $N_{\lambda_{ij}}$  вибираємо узагальнену похибку багатошарової нейронної мережі. Відповідна математична модель має вигляд

$$\varepsilon(N_{\lambda_{ij}}) \rightarrow \varepsilon_{\min}; N_{\lambda_{ij}} \in [1, \infty). \quad (2.3.6)$$

У наближенні нелінійної моделі узагальнену похибку  $\varepsilon$  з урахуванням умов (2.3.5) запишемо у вигляді [116]:

$$\varepsilon = \frac{N_{in}}{N_{\lambda_{ij}}} + \frac{N_{\lambda_{ij}}}{N_p} + \frac{N_{\lambda_{ij}}^2}{N_p^2}. \quad (2.3.7)$$

Як видно з співвідношення (2.3.7) збільшення кількості синаптичних зв'язків  $N_{\lambda_{ij}}$ , а відповідно число нейронів у прихованих шарах  $n_k$  ( $k=1,2,\dots,m$ , де  $k$  – номер шару) приводить до зменшення похибки апроксимації навчальних



даних. Тоді як друга складова  $\varepsilon_m$  узагальненої похибки  $\varepsilon$  приводить до збільшення похибки опису моделі  $\varepsilon_m$ .

Для визначення мінімального значення узагальненої похибки  $\varepsilon_{\min}$ , яке відповідає оптимальній кількості синаптичних зв'язків  $N_{\lambda_{ij}}^{opt}$  необхідно розв'язати рівняння:

$$\frac{\partial \varepsilon}{\partial N_{\lambda_{ij}}} = 0. \quad (2.3.8)$$

Враховуючи (2.3.7), з рівняння (2.3.8) отримаємо вираз для оптимальної кількості синаптичних зв'язків  $N_{\lambda_{ij}}^{opt}$

$$N_{\lambda_{ij}}^{opt} = -\frac{N_p}{6} + \frac{N_p^2}{6 \cdot \left(54N_{in}N_p^2 - N_p^3 + 6\sqrt{3}\sqrt{27N_{in}^2N_p^4 - N_{in}N_p^5}\right)^{\frac{1}{3}}} + \frac{1}{6} \left(54N_{in}N_p^2 - N_p^3 + 6\sqrt{3}\sqrt{27N_{in}^2N_p^4 - N_{in}N_p^5}\right)^{\frac{1}{3}}. \quad (2.3.9)$$

Як видно з формули (2.3.9), оптимальна кількість синаптичних зв'язків  $N_{\lambda_{ij}}^{opt}$  нелінійно залежить від числа вхідних образів  $N_{in}$  та числа навчальних прикладів  $N_p$ .

Підставивши  $N_{\lambda_{ij}}^{opt}$  (2.3.9) у формулу (2.3.7), отримаємо мінімальне значення узагальненої похибки  $\varepsilon_{\min} = \varepsilon_{|N_{\lambda_{ij}}=N_{\lambda_{ij}}^{opt}}$  багатошарового перцептрона.

Взаємозв'язок між загальною кількістю синаптичних зв'язків  $N_{\lambda_{ij}}$  та кількістю нейронів у прихованих шарах  $n_k$  багатошарового перцептрона визначається формулою [113]

$$N_{\lambda_{ij}} = N_{in} \cdot n_1 + \sum_{k=1}^{m-1} (n_k \cdot n_{k+1}) + n_m \cdot n_{out}, \quad (2.3.10)$$

де  $n_{out}$  – кількість нейронів у вихідному шарі.

Маючи вирази (2.3.9) та (2.3.10) для розрахунку оптимальної кількості синаптичних зв'язків  $N_{\lambda_{ij}}^{opt}$ , можна визначити оптимальну кількість нейронів  $n_k^{opt}$  у прихованих шарах нейромережі.

Для представлення довільної функції згідно з теоремою Хехт-Нільсена [94] достатньо тришарової нейромережі (з одним прихованим шаром,  $m=1$ ). Згідно з формулою (2.3.10) та урахуванням співвідношення (2.3.9), оптимальна кількість нейронів у одному прихованому шарі  $n_1^{opt}$  тришарової нейронної мережі буде визначатись:

$$n_1^{opt} = \frac{-\frac{N_p}{6} + \frac{N_p^2}{6 \cdot (54N_{in}N_p^2 - N_p^3 + 6\sqrt{3}\sqrt{27N_{in}^2N_p^4 - N_{in}N_p^5})^{\frac{1}{3}}} + \frac{1}{6} \left( 54N_{in}N_p^2 - N_p^3 + 6\sqrt{3}\sqrt{27N_{in}^2N_p^4 - N_{in}N_p^5} \right)^{\frac{1}{3}}}{N_{in} + n_{out}}. \quad (2.3.11)$$

#### 2.4. Шифрування інформації на основі синтезу діагоналізованої нейронної мережі та алгоритму AES

Криптографія є важливим компонентом контролю аутентифікації, інтеграції, конфіденційності та надійності зберігання даних, що пересилаються через відкриті мережі.

У сучасній практичній криптографії використовують два види ключів: симетричні (алгоритм з закритим ключем) та асиметричні (алгоритм з відкритим ключем). Основним недоліком симетричного шифрування є загальний ключ для шифрування і дешифрування, що ускладнює використання симетричного шифрування в розподілених системах. Проблема виникає через те, що ключ передається через загальнодоступний канал зв'язку, через який можна викрасти як саму інформацію, так і ключ для її дешифрування. В асиметричному шифруванні використовується два ключі: один ключ для шифрування і другий – для дешифрування. Один з ключів є секретним і знаходиться у сторони, яка створила цю пару ключів, а другий – розданий для шифрування. Процес шифрування реалізується таким чином, що повідомлення, яке зашифроване за допомогою відкритого ключа, може бути дешифроване тільки відповідним секретним ключем, тоді як повідомлення, яке зашифроване за допомогою

закритого ключа може бути розшифроване тільки за допомогою відкритого ключа.

Серед сучасних напрямків розробки ефективних і стійких методів криптографічного захисту актуальні технології штучних нейронних мереж [5], які вирізняються різноманітністю їхніх архітектур та алгоритмів навчання, а також можливостями гнучкого налаштування, зокрема і для задач шифрування даних [117].

У алгоритмі шифрування з використанням нейронних мереж ключем шифрування є вагові коефіцієнти синаптичних зв'язків. У цьому випадку для розшифрування морфології ключа необхідно знати значення всіх структурних характеристик і параметрів нейромережі.

Винятковою особливістю нейронних мереж є те, що за допомогою них можна представити довільну функцію багатьох змінних [94], у тому числі криптографічну. Апроксимуючи нейронною мережею функцію багатьох змінних (тобто, уже існуючий алгоритм, наприклад, DES або AES), можна значно підвищити ступінь захищеності від атак по стороннім каналам, оскільки:

- кожний нейрон містить в собі незначну частину інформації, яка необхідна для точної роботи алгоритму. В цьому випадку криптоаналітику необхідно проаналізувати значне число комірок пам'яті;
- обчислення проводять для кожного нейрона незалежно від вхідних даних. Внаслідок час роботи нейромережі буде залежати від її морфології, топології та розмірів;
- за ваговими коефіцієнтами синаптичних зв'язків нейронної мережі неможливо визначити, яким був секретний ключ, а в деяких випадках сам алгоритм шифрування.

При реалізації AES за допомогою нейронної мережі, криптосистема AES є нелінійна в експлуатації і має більш складну будову, ніж проста AES. Нелінійною повинна бути нейронна мережа зі зворотнім зв'язком, що дозволить виконати шифрування відкритого тексту або дешифрування зашифрованого тексту з високою продуктивністю і низьким рівнем помилок. Нелінійність необхідна для

зменшення імовірності виявлення кроків алгоритму. Зменшення імовірності злому алгоритму досягається за допомогою нелінійної функції активації. На сьогодні найбільш популярним видом штучних нейронних мереж в задачах криптографії є багатошаровий перцептрон прямого поширення, оскільки його властивістю є здатність емулювати будь-які співвідношення входів та виходів. Багатошаровий перцептрон відповідає за частоту оновлення, оскільки він оновлює вагові коефіцієнти синаптичних зв'язків після того, як блок навчальних даних представлений повністю. Блочна адаптація є більш надійною з того моменту, коли крок навчання усереднений за всіма навчальними шаблонами [118].

У цій задачі пропонується розробка системи шифрування інформації на основі синтезу діагоналізованої нейронної мережі та алгоритму AES (Advanced Encryption Standard(Rijndael)) [119]. Система шифрування базується на діагоналізації матриці вагових коефіцієнтів синаптичних зв'язків нейронної мережі у базисі векторів вхідних образів, що забезпечує формування нового ключа для кожного вхідного образу. Запропонований підхід забезпечує при шифруванні інформації постійно змінний ключ, тобто підвищує ступінь криптостійкості алгоритму порівняно з існуючими алгоритмами шифрування.

Розглянемо архітектуру модифікованої нелінійної нейронної мережі з діагональними синаптичними зв'язками.

Операція діагоналізації матриці синаптичних зв'язків здійснюється на основі співвідношень (2.1.5) – (2.1.9).

Операція діагоналізації [104] використовується для побудови асиметричного постійно змінного ключа шифрування та спрощеного налаштування вагових коефіцієнтів синаптичних зв'язків у нейронній мережі в процесі її навчання завдяки зміні конфігурації мережі способом перетворення повнозв'язної матриці синаптичних зв'язків до діагональної матриці (Рис. 2.4.1).

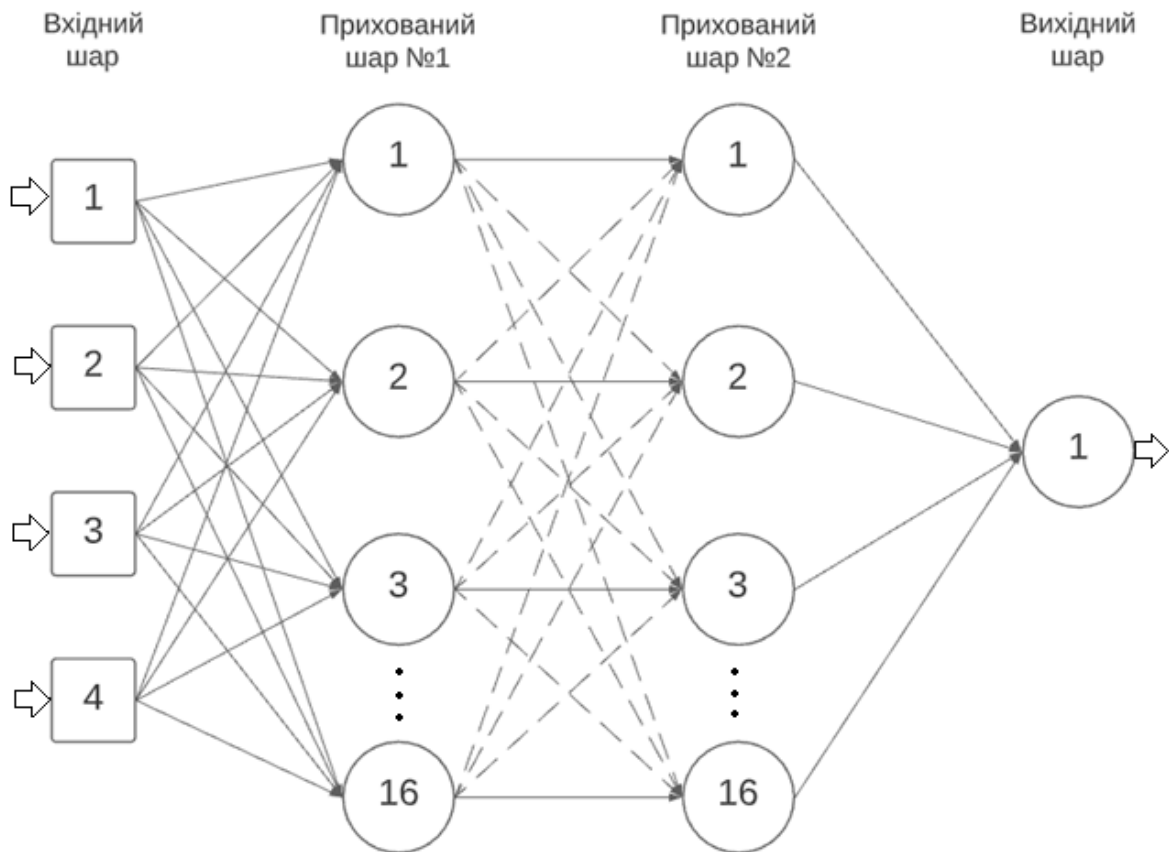


Рис. 2.4.1. Структура нейронної мережі прямого поширення після діагоналізації матриці вагових коефіцієнтів синаптичних зв'язків  $\lambda_{ik}$ .

Аналіз структури нейронної мережі (Рис. 2.4.1) показує, що до діагоналізації число синаптичних зв'язків між прихованими шарами було  $N^2$ , тоді як після діагоналізації стало  $N$ . Необхідно зауважити, що недіагональні компоненти синаптичних зв'язків не зникають, а містяться в перенормованих елементах головної діагоналі після діагоналізації. Така зміна числа і структури вагових коефіцієнтів синаптичних зв'язків приводить до трансформації ключа шифрування з підвищеним ступенем криптостійкості, що забезпечує формування нового ключа для кожного вхідного образу.

Діагоналізована нейронна мережа представляє собою структуру (Рис. 2.4.1), яка складається з множини штучних нейронів, з'єднаних між собою головними компонентами синаптичних зв'язків  $\tilde{\lambda}_{ii}$ , що є функціями від недіагональних компонентів. Головні компоненти синаптичних зв'язків  $\tilde{\lambda}_{ii}$  будуються в базисі

векторів вхідних образів. Кожний нейрон має характерний вхід та вихід, і реалізує локальне обчислення або функцію. Вихід будь-якого нейрона визначається характеристиками його входу та виходу, його взаємозв'язками з іншими нейронами, а також зовнішніми входами.

Для процесу шифрування використовуємо такі параметри:

- вхідний вектор, який описує відкритий текст;
- вихідний вектор – зашифрований текст алгоритмом AES за допомогою діагоналізованої нейронної мережі;
- ключем шифрування є вагові коефіцієнти діагоналізованої матриці синаптичних зв'язків нейронної мережі;
- структура ключа є асиметричною та визначається базисом векторів вхідних образів, які формують новий ключ для кожного вхідного образу;
- нелінійна функція активації кожного нейрона є сигмоїдальною і на виході дає значення між  $(0 - 1)$ .

Для процесу дешифрування використовуємо такі параметри:

- вхідним вектором є шифротекст;
- вихідні значення – відкритий текст;
- ключем дешифрування є вагові коефіцієнти оберненої діагоналізованої матриці синаптичних зв'язків нейронної мережі;
- нелінійна функція активації кожного нейрона є сигмоїдальною і на виході дає значення між  $(0 - 1)$ .

У процесі навчання діагоналізованої нейронної мережі, синтезованої з алгоритмом AES, спочатку на нейронну мережу поступає відкритий текст у ролі вхідних векторів, після чого на виході нейронної мережі отримуємо текст, який порівнюється з еталонним (цільовим) шифротекстом та при потребі корегуються вагові коефіцієнти синаптичних зв'язків для того, щоб вихідний текст нейромережі відповідав еталонному (цільовому) шифротексту.

У шифруванні й дешифруванні у ролі нелінійної функції активації для кожного нейрона використовують сигмоїдальну функцію [6]. Дані, що

використовуються в AES, знаходяться в діапазоні (0 – 255). Отже, щоб нейронна мережа була сумісна з даними AES на етапі функції активації, необхідно перетворити ці дані в діапазон (0 – 1). Це досягається за допомогою масштабування (нормалізації) з коефіцієнтом (1 / 256) у такий спосіб, щоб було суміщення з виходом функції активації. Коефіцієнт може бути використаний на виході кожного нейрона для оберненого перетворення вихідного діапазону в інтервал (0 – 255). У цьому разі використовуємо версію AES-128, яка має 128-бітний ключ [120]. Унаслідок нейронна мережа має вхід і вихід розмірністю 16 байт. Отже, нейронна мережа повинна мати хоча б один прихований шар, який складається з 16 нейронів для досягнення розміру вхідного ключа довжиною 16 байт. Структура ключа є асиметричною та визначається базисом векторів вхідних образів, які формують новий ключ для кожного вхідного образу.

Найоптимальнішою топологією для системи шифрування, синтезованої з алгоритму AES та нейронної мережі з діагоналізованими ваговими синаптичними зв'язками, є (4 — 16 — 16 — 1).

Вихід діагоналізованої нейронної мережі буде описуватись наступним співвідношенням:

$$output = \tanh \left( \sum_{k=1}^{16} \lambda_{k1} \cdot \tanh \left( \sum_{i=1}^{16} \tilde{\lambda}_{ii} \cdot \tanh \left( \sum_{i=1}^{16} \sum_{j=1}^4 \lambda_{ji} \cdot \tanh \left( \sum_{i=1}^4 \lambda_{1j} \cdot input \right) \right) \right) \right), \quad (2.4.1)$$

де *output* – зашифрований текст,  $\lambda$  – ключ у вигляді матриці, *input* – відкритий текст.

Враховуючи зазначену вище топологію системи шифрування, у дисертаційному дослідженні архітектура діагоналізованої нейро-криптосистеми AES складається з таких елементів:

- перший шар з 4 нейронів, де кожен нейрон отримує один байт з вхідного вектора (відкритий або зашифрований текст);
- другий шар з 16 нейронів, де кожен нейрон сумує ваги всіх нейронів першого шару;

- третій шар з 16 нейронів, де кожен нейрон сумує головні компоненти ваги всіх нейронів другого шару;
- четвертий шар з 1 нейроном, сумує ваги всіх нейронів третього шару.

Для оцінки коефіцієнта криптостійкості алгоритму використаємо кореляційний аналіз, який виявляє ступінь подібності між сигналами на вході та виході нейронної мережі. Коефіцієнти криптостійкості недиагоналізованої нейро-криптосистеми AES  $K_1$  та діагоналізованої нейро-криптосистеми AES  $K_2$  будемо визначати

$$K_1 = 1 - |r_{V,y}^{(1)}|, \quad (2.4.2)$$

$$K_2 = 1 - |r_{V,y}^{(2)}|, \quad (2.4.3)$$

де  $|r_{V,y}^{(1)}|$  та  $|r_{V,y}^{(2)}|$  – нормовані коефіцієнти кореляції між сигналом на вході та виході недиагоналізованої та діагоналізованої нейронної мережі відповідно:

$$r_{V,y}^{(1)} = \frac{\frac{1}{N} \sum_{i=1}^N (V_i - \bar{V})(y_i^{(1)} - \bar{y}_1)}{\sqrt{\left(\frac{1}{N} \sum_{i=1}^N (V_i - \bar{V})^2\right) \left(\frac{1}{N} \sum_{i=1}^N (y_i^{(1)} - \bar{y}_1)^2\right)}}, \quad (2.4.4)$$

$$r_{V,y}^{(2)} = \frac{\frac{1}{N} \sum_{i=1}^N (V_i - \bar{V})(y_i^{(2)} - \bar{y}_2)}{\sqrt{\left(\frac{1}{N} \sum_{i=1}^N (V_i - \bar{V})^2\right) \left(\frac{1}{N} \sum_{i=1}^N (y_i^{(2)} - \bar{y}_2)^2\right)}}, \quad (2.4.5)$$

де  $V_i$  та  $y_i^{(1)}$ ,  $y_i^{(2)}$  – послідовність даних (дискретний сигнал) на вході та виході нейронних мереж;  $\bar{V} = \frac{1}{N} \sum_{i=1}^N V_i$  та  $\bar{y}_1$ ,  $\bar{y}_2$  – середні значення сигналу на вході та виході нейронних мереж.

Для того, щоб коефіцієнт криптостійкості  $K_2$  у випадку діагоналізованої нейро-криптосистеми AES був більший за коефіцієнт криптостійкості  $K_1$ , необхідно, щоб виконувалася умова  $|r_{V,y}^{(2)}| < |r_{V,y}^{(1)}|$ . Такий критерій буде



виконуватися, коли функція  $y_i^{(2)} = \varphi_2(V_1, V_2, \dots, V_N)$  буде задовольняти умові повільно змінної функції (3.2.5).

Аналіз результатів дослідження показує, що криптосистема, побудована на основі синтезу алгоритму AES з діагоналізованою нейронною мережею, яка використовує нелінійну функцію активації і метод постійно змінних ключів для кожного окремого вхідного образу, є більш стійкою до відомих атак, ніж сам алгоритм AES [120] та недіагоналізована нейро-криптосистема AES [5]. Для шифрування та дешифрування блоків з даними більшої довжини можна використовувати іншу топологію діагоналізованої нейромережі та асиметричні ключі більших розмірів.

## Висновки до розділу 2

1. Розроблено метод стиску вхідних образів нейронною мережею на основі діагоналізації матриці синаптичних зв'язків, що приводить до переміщення інформації з недіагональних компонент синаптичних зв'язків до головних діагональних компонент, внаслідок чого інформація стискається.

2. Встановлено, що діагоналізація матриці синаптичних зв'язків зумовлює підвищення швидкості налаштування вагових синаптичних зв'язків у процесі навчання нейронної мережі завдяки зменшенню числа синаптичних зв'язків між нейронами. При такій трансформації структури синаптичних зв'язків взаємодія між усіма нейронами не зникає, а враховується у перенормованих головних зв'язках.

3. Доведено модифіковану теорему Хехт-Нільсена, яка описує алгоритм апроксимації функції від  $n$  змінних з заданою точністю  $\varepsilon > 0$  за допомогою однієї операції агрегування у тришаровій штучній нейронній мережі (з одним прихованим шаром), що в свою чергу зменшує використовуваний обчислювальний ресурс та час налаштування вагових коефіцієнтів синаптичних зв'язків у нейронній мережі.

4. Розроблено нелінійну модель узагальненої похибки для нейронної мережі прямого поширення. Встановлено оптимальне число синаптичних зв'язків та оптимальне число нейронів у прихованому шарі тришарової нейромережі.

5. Побудовано діагоналізовану нейро-криптосистему AES на основі синтезу алгоритму AES та нейронної мережі з діагональними синаптичними зв'язками, яка забезпечує формування нового асиметричного ключа для кожного вхідного образу.

6. Встановлено, що запропонований підхід шифрування інформації діагоналізованою нейро-криптосистемою AES з постійно змінним ключем підвищує ступінь криптостійкості алгоритму порівняно з існуючими алгоритмами шифрування.

## РОЗДІЛ 3. ОСЦИЛЯТОРНІ НЕЙРОННІ МЕРЕЖІ З ЛІНІЙНИМИ ТА НЕЛІНІЙНИМИ ОСЦИЛЯТОРНИМИ НЕЙРОНАМИ

### 3.1. Математична модель нейронної мережі з лінійними осциляторними нейронами. Критерій виникнення інформаційного резонансу

На сьогодні ведуться інтенсивні дослідження щодо застосування нейронних мереж з осциляторними нейронами для ідентифікації нестационарних процесів, класифікації, кластеризації та розпізнавання мультиспектральних образів.

Необхідно зауважити, що осциляторні нейронні мережі, математичні моделі яких були розглянуті у огляді літератури (моделі «integrate-and-fire», Іжикевича, Фітза Хуга-Нагумо, Хіндмарша-Роуза) [16 – 28], не враховують: власної динаміки нейрона (власна частота коливань нейрона –  $\omega_{0m} = 0$ ), накопичення імпульсів  $N_{0k}$  в нейронах, які спрацьовують, коли  $N_{0k} \geq N_{ck}$  ( $N_{ck}$  – порогове значення імпульсів  $k$ -го нейрона) та нелокальність за часом.

Тому актуальною задачею є розробка штучної нейронної мережі з осциляторними нейронами, які мають власні частоти ( $\omega_{0m}, m = 1, 2, \dots, M$ ). За допомогою такого типу штучної нейронної мережі на основі інформаційного резонансу можна реалізувати новий метод розпізнавання мультиспектральних образів (мультиспектральних електромагнітних сигналів), що випромінюють осциляторні об'єкти. До них відносяться нестационарні сигнали, які випромінюються зарядженими наночастинками гетерофазної плазми, що утворюються внаслідок згорання твердого палива під час польоту ракети, високотемпературні викиди промислових аерозолів, іонізовані пило-газові утворення в атмосфері і космосі, продукти руйнації метеоритів при їх взаємодії з атмосферою Землі, скупчення космічного пилу в умовах дії іонізуючої радіації.

Розглянемо математичну модель архітектури нейронної мережі з лінійними осциляторними нейронами, яка описує залежність прийняття рішення, згідно з якою значення вихідного вектора станів  $\vec{Y}_k = \{y_1(\omega_1), y_2(\omega_2), \dots, y_k(\omega_k)\} \subset \vec{Y}$  можуть бути оцінені з відомих значень вектора вхідних характеристик

$\vec{V}_n = \{V_1(\omega_1), V_2(\omega_2), \dots, V_n(\omega_n)\} \subset \vec{V}$  ( $V_n(\omega_n)$ ,  $n = \overline{1, N}$  –  $n$ -ий компонент вектора вхідної спектральної характеристики). Для розпізнавання мультиспектральних вхідних образів  $\vec{V}_n = \{V_1(\omega_1), V_2(\omega_2), \dots, V_n(\omega_n)\} \subset \vec{V}$  пропонується тришаровий перцептрон з осциляторними нейронами. Він має вхідний шар, який містить кількість нейронів, що дорівнює кількості вхідних атрибутів; прихований шар і вивід, в якому шар містить кількість осциляторних нейронів, що дорівнює кількості класів рішень.

Прихований шар складається з  $M$  осциляторних нейронів  $m = \overline{1, M}$  з власною частотою коливань  $\omega_{0m}$ , на які поступає інформація з першого шару, що має  $N$  входів. На вхід  $m$ -го осциляторного нейрона у прихованому шарі поступає  $N$  мультиспектральних образів  $\vec{V}_n = \{V_1(\omega_1), V_2(\omega_2), \dots, V_n(\omega_n)\} \subset \vec{V}$

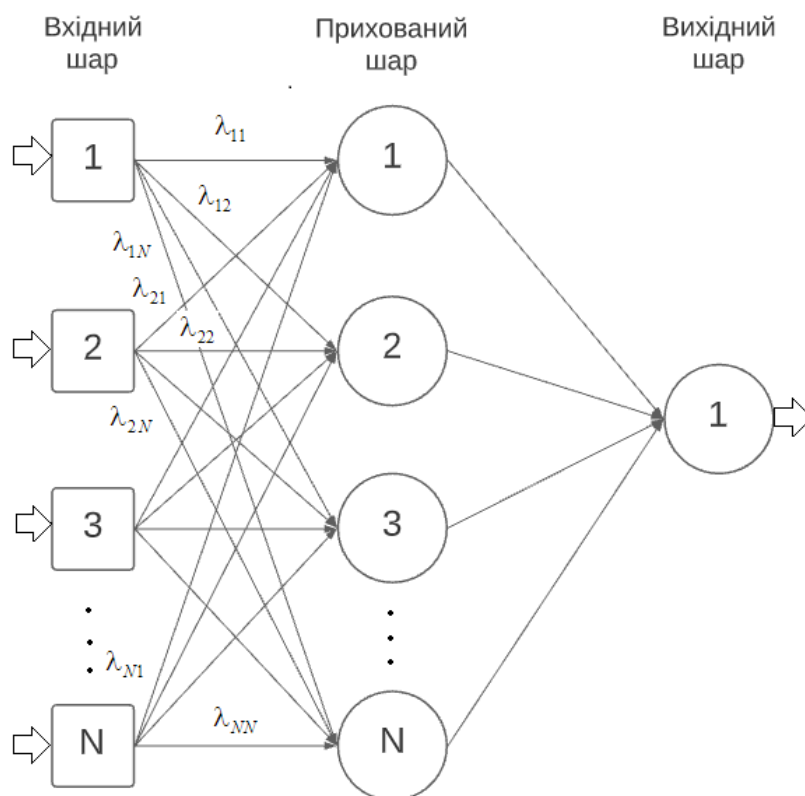


Рис. 3.1.1. Тришарова осциляторна нейронна мережа

$$V_m = \sum_{n=1}^N \tilde{V}_{nm} \cdot \tilde{\omega}_{nm}^2 \cdot \sin^2(\tilde{\omega}_{nm} \cdot \tau) + \tilde{V}_{0m}, \quad (3.1.1)$$

де  $\tilde{V}_{nm}$  – ваговий коефіцієнт  $n$ -ої вхідної характеристики, що входить на вхід  $m$ -го осциляторного нейрона прихованого шару;  $\tilde{V}_{0m}$  – поріг.

Функціонування  $m$ -го лінійного осциляторного нейрона описується неоднорідним осциляторним диференціальним рівнянням 2-го порядку:

$$\frac{d^2 U_m}{d\tau^2} + 2\tilde{\delta} \frac{dU_m}{d\tau} + \tilde{\omega}_{0m}^2 U_m = \sum_{n=1}^N \tilde{V}_{nm} \omega_{nm}^2 \sin^2(\omega_{nm} \tau), \quad (3.1.2)$$

де  $2\tilde{\delta}(N_k, N_{ck}) = \delta \tanh\left(\frac{N_k - N_{ck}}{\sigma^2}\right)$  – параметр амплітуди затухання  $m$ -го нейрона;

$N_k; N_{ck}; \sigma^2$  – число імпульсів, які приходять на  $m$ -ий нейрон, порогове значення імпульсів  $m$ -го нейрона та дисперсія відповідно.

Математична модель (3.1.2) може використовуватися для дослідження колективної поведінки ансамблів нейронів, взаємопов'язаних синаптичними зв'язками  $\lambda_{jm}$ . Для цього в другому та третьому доданках необхідно зробити

заміну  $U_m \rightarrow U_{\alpha m}$ , де  $U_{\alpha m} = U_m + \sum_{j=1}^N \lambda_{jm} U_j$ ;  $\alpha = 1, 2, \dots, N$  [121 – 123].

Вихідний сигнал  $m$ -го осциляторного нейрона  $U_m(\tau)$  описується виразом, який є розв'язком рівняння (3.1.2)

$$U_m(t) = \sum_{n=1}^N \tilde{C}_{nm} + \sum_{n=1}^N \tilde{\lambda}_{nm} |\sin(2\tilde{\omega}_{nm} \tau + \tilde{\phi}_n)|, \quad (3.1.3)$$

$$\tilde{C}_{nm} = \frac{16\tilde{V}_{nm} \tilde{\delta}^2 \tilde{\omega}_{nm}^4 + \tilde{V}_{nm} \tilde{\omega}_{nm}^2 (\tilde{\omega}_{0m}^2 - 4\tilde{\omega}_{nm}^2)^2}{2\tilde{\omega}_{0m}^2 (16\tilde{\delta}^2 \tilde{\omega}_{nm}^2 + (\tilde{\omega}_{0m}^2 - 4\tilde{\omega}_{nm}^2)^2)}, \quad (3.1.4)$$

$$\tilde{\lambda}_{nm} = \frac{\tilde{V}_{nm} \tilde{\omega}_{nm}^2 / 2}{\sqrt{(\tilde{\omega}_{0m}^2 - 4\tilde{\omega}_{nm}^2)^2 + 16\tilde{\delta}^2 \tilde{\omega}_{nm}^2}}, \quad (3.1.5)$$

$$\tilde{\omega}_m^{res} = \frac{\omega_{0m}^2}{2\sqrt{\omega_{0m}^2 - 2\delta^2}}, \quad (3.1.6)$$

$$\tilde{\lambda}_m^{res} = \frac{\tilde{V}_{nm} \omega_{0m}^2}{16\delta \sqrt{\omega_{0m}^2 - \delta^2}}, \quad (3.1.7)$$

де  $\tilde{\omega}_m^{res}$  – резонансне значення частоти  $m$ -того нейрона;  $\tilde{\lambda}_m^{res}$  – резонансне значення синаптичного зв'язку між  $m$ -им та  $n$ -им нейронами;  $\tilde{\omega}_{nm}$  – частота  $n$ -го спектрального образу, що поступає на  $m$ -ий осциляторний нейрон у прихованому шарі.

Необхідно зазначити, для того, щоб були коливання необхідно, щоб у формулі (3.1.6)  $2\delta^2 < \omega_{0m}^2$ . В іншому випадку коливань не буде, тому що  $\tilde{\omega}_m^{res}$  буде комплексним.

Оскільки у біологічних нейронах після потенціалу дії мембрани нейронної клітини існує рефрактерний період (час релаксації  $t_r = 2мс - 30мс$ ), тому в штучному нейроні, при його функціонуванні в неперервному (дискретному) часі необхідно ввести нелокальність за часом – запізнення  $t_r$ . Таке введення дає змогу також згладжувати випадкові стрибки сигналу  $U_m(\tau)$ . Нелокальність може здійснювати як суматор, так і сам нейрон. Якщо нелокальність задається лінійно, то можна записати:

$$\tilde{U}_m(\tau) = \int_0^{t_r} e^{-\alpha_1 t} U_m(\tau - t) dt, \quad (3.1.8)$$

де  $U_m(\tau - t)$  розв'язок (3.1.3) рівняння (3.1.2);  $0 < \alpha_1 < 1$ .

Підставивши формулу (3.1.5) у формулу (3.1.3) з урахуванням  $|\sin(2\tilde{\omega}_{nm}\tau + \tilde{\varphi}_n)| \leq 1$ , отримаємо нерезонансне амплітудне значення на виході  $m$ -го нейрона, коли на вхід цього нейрона поступає  $N$  мультиспектральних сигналів. Відповідно до цього отримаємо:

$$U_m = \sum_{n=1}^N \tilde{V}_{nm} x_n, \quad (3.1.9)$$

$$\text{де } x_n = \frac{\tilde{\omega}_{nm}^2 / 2}{\sqrt{(\tilde{\omega}_{0m}^2 - 4\tilde{\omega}_{nm}^2)^2 + 16\delta^2 \tilde{\omega}_{nm}^2}}.$$

Для отримання резонансного амплітудного значення сигналу підставимо (3.1.7) у формулу (3.1.3) та отримаємо:

$$U_m^{res} = \sum_{n=1}^N \tilde{V}_{nm} \frac{\omega_{0m}^2}{16\delta\sqrt{\omega_{0m}^2 - \delta^2}}. \quad (3.1.10)$$

Необхідною умовою розпізнавання мультиспектральних образів за резонансним ефектом є виконання нерівності  $|\tilde{\omega}_{nm} - \tilde{\omega}_{res}| \leq \varepsilon$ , де  $0 < \varepsilon \ll 1$ .

Вихідний шар нейронів має порогову функцію активації. Ці нейрони використовують для визначення певного класу рішень, до якого належать (або не належать) вхідні спектральні образи.

$$y = \varphi\left(\sum_{m=1}^M v_m U_m - v_0\right) = \begin{cases} 1, & \text{якщо } \sum_{m=1}^M v_m U_m - v_0 \geq 0 \\ 0, & \text{якщо } \sum_{m=1}^M v_m U_m - v_0 < 0 \end{cases}; \quad (3.1.11)$$

де  $y$  – вихідний сигнал лінійного осциляторного нейрона,  $v_m$  – вагові коефіцієнти між нейронами прихованого шару та нейроном вихідного шару.

Якщо зовнішній сигнал з частотою  $\omega_{nm}$  співпадає з частотою власних коливань нейрона  $\omega_{0m}$ , то виникає інформаційний резонанс з амплітудою, якій приписується булева одиниця. Критерієм розпізнавання сигналу з амплітудою співмірною рівню шуму при резонансі є мінімальна евклідова відстань між частотою зовнішнього сигналу та власною частотою коливань осциляторних нейронів, яка повинна бути меншою за ширину частотного спектру шумового сигналу.

### 3.2. Математична модель нейронної мережі з нелінійними осциляторними нейронами

З аналізу літературних джерел [16 – 28] випливає, що існуючі моделі нелінійних осциляторних нейронних мереж мають певні недоліки. Зокрема:

- коли різні нейрони мають різну динаміку, кожному збуджувальному нейрону потрібно приписувати інше значення параметрів, що вимагає збільшення обчислювального ресурсу;

- не враховується число імпульсів струму, які подаються на вхід нейронів;
- взаємодія нейронів враховується тільки завдяки однієї випадкової змінної, яка однорідно розподілена на інтервалі  $[0, 1]$ , що входить в параметри моделі;
- не враховується час релаксації нейрона після потенціалу його дії;

У роботах [124, 125] автори сформулювали припущення, що нейрони мозку людини генерують опорні хвилі різної частоти ( $\omega_{0i}, i=1,2,\dots,k$ ). За допомогою опорних хвиль з визначеною періодичністю здійснюються «опитування» нейронів, тобто реалізується аналіз вхідного зображення на різних частотах і порівнюються відгуки на вхідні образи, які раніше були запам'ятовані. При цьому кожний нейрон, який працює за принципом «питання – відповідь», відповідає тільки на те питання, на яке «знає» відповідь, як це виконує, наприклад, нейрон Гроссберга. Основою нейронів мозку людини є мікротрубочки цитоскелету [102, 103, 126]. Субодинаміями мікротрубочки цитоскелету є молекули тубуліна. Структура такої молекули представляє собою димер, тобто складається з двох частин ( $\alpha$  і  $\beta$  – тубулін) з'єднаних за допомогою тонкої перемички. Приблизні резонансні частоти молекул тубуліна, які є субодинаміями мікротрубочки цитоскелету, складають  $\omega_{0i}^{res} = 10^{11} \text{ Hz} - 10^{13} \text{ Hz}$  [127]. Таким чином, можна припустити, що резонансна частота біологічних нейронів приблизно буде такою ж, як резонансна частота молекул тубуліна.

Розглянемо сенсорний нелінійний осциляторний нейрон виду Ван-Дер-Поля (пороговий пристрій) з власною динамікою  $\omega_{0k}$ , який здатний генерувати імпульси за відсутності зовнішніх нестационарних сигналів ( $V_k(t) = 0$ ), коли кількість наявних у сенсорному нейроні імпульсів  $N_{0k}$  досягає порогового значення  $N_{ck}$  ( $N_{0k} > N_{ck}$ ). Тобто, такий нейрон може розглядатися як пороговий пристрій, який перетворює вхідний нестационарний сигнал  $V_k(t)$  на послідовність імпульсів на виході (Рис. 3.2.1) внаслідок «накладання» динаміки вхідного




нестационарного сигналу  $V_k(t)$  на власну динаміку нейрона. Через це аналіз процесу перетворення сигналів сенсорним нелінійним осциляторним нейроном ускладнюється. Про складну динаміку перетворення вхідного нестационарного сигналу, що подається на біологічний сенсор з власною динамікою, свідчить експериментальний запис сигналу (Рис. 3.2.2) [128], що генерується біологічним нейроном без дії зовнішнього сигналу (інтервал  $0 < t < 110c$  з послідовністю низькочастотних  $\delta$ -імпульсів). На інтервалі часу  $110c < t < 200c$  з (Рис. 3.2.2) зображено результат взаємодії зовнішнього сигналу з біологічним сенсором з власною динамікою, яка приводить до формування послідовності високочастотних  $\delta$ -імпульсів.

Тоді задача динаміки нелінійного осциляторного нейрона за наявності зовнішніх нестационарних сигналів різних за формою, частотою та амплітудою полягає у визначенні частотно-часової та часової залежності морфології сигналу на виході нелінійного осциляторного нейрона в межах нелінійної моделі Ван-дер-Поля з урахуванням порогового ефекту нейрона та встановленні критерію виникнення резонансних ефектів у нелінійному осциляторному нейроні.

Авторами роботи [128] на основі техніки подвійного вейвлет-аналізу було досліджено частотно-часову динаміку сенсорного нейрона (порогового пристрою) з урахуванням взаємодії його власної динаміки та динаміки, зумовленої дією зовнішнього нестационарного сигналу. При цьому сенсорний нейрон моделювався як пороговий пристрій, що перетворює вхідний сигнал у послідовність імпульсів на виході. Ця послідовність імпульсів описувалась послідовністю дельта-функцій Дірака, кожна з яких відповідає моменту генерації імпульсу (спайку). Ці модельні імпульси мають однакову форму і амплітуду, тому інформація про зовнішню дію осциляторного сигналу відображається тільки в часових інтервалах між моментами їх генерації.



*Рис. 3.2.1. Схематичне зображення процесу перетворення вхідного сигналу  $V_k(t)$  сенсорним нелінійним осциляторним нейроном (пороговим пристроєм). Часи генерації імпульсів на виході порогового пристрою  $X_k(t)$  відповідають моментам перетину порогового рівня*



*Рис. 3.2.2. Приклад експериментального запису сигналу, що генерується біологічним нейроном*

Нейронна мережа  $N$  нелінійних взаємопов'язаних осциляторних нейронів до здійснення діагоналізації матриці вагових синаптичних зв'язків описується системою  $N$  нелінійних рівнянь (3.2.1) відповідно:

$$\ddot{X}_k + \mu_k \left\{ \left[ X_k + \sum_{j=1}^N \lambda_{jk} X_j \right]^2 - p_k^2(N_{0k}; N_{ck}) \right\} \dot{X}_k + \omega_{0k}^2 \left[ X_k + \sum_{j=1}^N \lambda_{jk} X_j \right] = V_k(t), \quad (3.2.1)$$

де  $k=1,2,3,\dots,N$ ;  $V_k(t) = \begin{cases} V_1(t), k=1 \\ X_{k-1}(t), k=2,3,4,5,\dots,N \end{cases}$ ;  $\lambda_{jk} = 0$  при  $j=k$ .

$V_1(t)$  – несучий інформаційний сигнал, який поступає на перший нелінійний нейрон мережі нейронів, взаємопов'язаних ваговими синаптичними коефіцієнтами  $\lambda_{jk}$ ;

$X_{k-1}(t)$  – спотворений  $(k-1)$  нейронами несучий інформаційний сигнал, що поступає на  $k$ -й нелінійний нейрон;

$p_k^2(N_{0k}; N_{ck}) = p_{0k}^2 \tanh\left(\frac{N_{0k} - N_{ck}}{\sigma_k^2}\right)$  – параметр амплітуди  $k$ -го нейрона;

$N_{0k}$ ,  $N_{ck}$ ,  $\sigma_k^2$  – число імпульсів, які приходять на  $k$ -й нейрон, порогове значення імпульсів  $k$ -го нейрона та дисперсія відповідно;

$\omega_{0k}^2$  – власна частота  $k$ -го нелінійного осциляторного нейрона;

$V_k(t)$  – вхідний нестационарний сигнал, який поступає на  $k$ -й нейрон.

Нелінійний осциляторний нейрон має власну динаміку і генерує імпульси за відсутності зовнішніх сигналів при  $N_{0k} > N_{ck}$ , оскільки за цієї умови  $\tanh\left(\frac{N_{0k} - N_{ck}}{\sigma_k^2}\right) > 0$  і відповідно  $p_k^2(N_{0k}; N_{ck}) > 0$  [129]. Дискретно-часова модель нелінійного осциляторного нейрона може бути отримана з аналогової нелінійної моделі способом конвертування диференціальних рівнянь у відповідні різницеві рівняння.

Використаємо операцію діагоналізації (співвідношення (2.1.5) – (2.1.9)) для нелінійної моделі системи взаємопов'язаних осциляторних нейронів (3.2.1).

Після операції діагоналізації вагових коефіцієнтів синаптичних зв'язків [моя робота]  $\lambda_{jk} \rightarrow \tilde{\lambda}_{jk} = \beta_j \delta_{jk}$  система  $N$  нелінійних рівнянь (3.2.1) набуде вигляду:

$$\ddot{X}_k + \mu_k \left\{ X_k^2 [1 + \beta_k]^2 - p_k^2(N_{0k}; N_{ck}) \right\} \dot{X}_k + \omega_{0k}^2 \left[ X_k [1 + \beta_k] \right] = V_k(t). \quad (3.2.2)$$

Діагоналізація матриці вагових синаптичних зв'язків приводить до розпаду системи нелінійних рівнянь (3.2.1) на окремі незалежні нелінійні рівняння (3.2.2).

Розв'язок рівняння (3.2.2) знаходимо методом Крилова-Боголюбова-Митропольського [130] і методом послідовних наближень у вигляді

$$X_k^{(n)}(t) = a_k^{(n)}(t) \sin \psi_k^{(n)}(t), \quad (3.2.3)$$

де  $n = 1, 2, 3, \dots, N$  – номер ітерації;

$$\psi_k^{(n)}(t) = \omega_{0k} t + \varphi_k^{(n)}(t), \quad (3.2.4)$$

де  $a_k^{(n)}(t)$  і  $\varphi_k^{(n)}(t)$  – функції часу, які добираються так, щоб співвідношення (3.2.3) задовольняло рівняння (3.2.2). Крім цього накладаємо умову, що  $a_k^{(n)}(t)$  є повільно змінна функція, тобто

$$\lim_{t \rightarrow \infty} \frac{a_k^{(n)}(p_k \mu_k t)}{a_k^{(n)}(p_k t)} = 1. \quad (3.2.5)$$

Але оскільки функцій є дві  $a_k^{(n)}(t)$  і  $\psi_k^{(n)}(t)$ , а рівняння одне, то ця умова неоднозначно визначає функції. Будемо вимагати, щоб виконувалась також умова

$$\dot{X}_k^{(n)} = \omega_{0k} a_k^{(n)}(t) \cos \psi_k^{(n)}(t), \quad (3.2.6)$$

де  $\dot{X}_k^{(n)} = \frac{dX_k^{(n)}(t)}{dt}$ .

Підставляючи (3.2.3) в (3.2.2) і враховуючи умову (3.2.6), отримаємо систему рівнянь для  $a_k^{(n)}(t)$  і  $\varphi_k^{(n)}(t)$  [123, 131, 132]:

$$\begin{cases} \frac{da_k^{(n)}(t)}{dt} = -a_k^{(n-1)}(t) \mu_k \left[ (a_k^{(n-1)})^2 (1 + \beta_k)^2 \sin^2 \psi_k^{(n-1)}(t) - p_k^2 (N_{0k}; N_{ck}) \right] \cos^2 \psi_k^{(n-1)}(t) + V_k(t) \cos \psi_k^{(n-1)}(t) \\ \frac{d\psi_k^{(n)}(t)}{dt} = \omega_{0k} + \mu_k \left[ (a_k^{(n-1)})^2 (1 + \beta_k)^2 \sin^2 \psi_k^{(n-1)}(t) - p_k^2 (N_{0k}; N_{ck}) \right] \sin \psi_k^{(n-1)}(t) \cos \psi_k^{(n-1)}(t) - \frac{V_k(t) \sin \psi_k^{(n-1)}(t)}{a_k^{(n-1)}(t)} \end{cases} \quad (3.2.7)$$

Усереднимо праву частину системи рівнянь (3.2.7) за період  $2\pi$  при  $V_k(t) = 0$  за правилом [130]:

$$\langle \Phi \rangle = \frac{1}{2\pi} \int_0^{2\pi} \Phi(\psi_k^{(n)}) d\psi_k^{(n)}. \quad (3.2.8)$$

У нульовому наближенні вирази для  $a_k^{(0)}(t)$  і  $\psi_k^{(0)}(t)$  знаходимо з такої системи рівнянь:

$$\frac{da_k^{(0)}(t)}{dt} = A(a_k^{(0)}(t)), \quad \frac{d\psi_k^{(0)}(t)}{dt} = B(a_k^{(0)}(t)), \quad (3.2.9)$$

$$\text{де } A(a_k^{(0)}(t)) = -a_k^{(0)}(t)\mu_k \left( \frac{(a_k^{(0)})^2}{8} (1 + \beta_k)^2 - \frac{p_k^2}{2} \right), \quad B(a_k^{(0)}(t)) = \omega_{0k} (1 + \beta_k).$$

Інтегруючи рівняння (3.2.9), отримаємо в нульовому наближенні вирази для  $a_k^{(0)}(t)$  і  $\psi_k^{(0)}(t)$ :

$$a_k^{(0)}(t) = \frac{2p_k}{\sqrt{(1 + \beta_k)^2 + e^{-p_k^2 \mu_k t}}}, \quad (3.2.10)$$

$$\psi_k^{(0)}(t) = \omega_{0k} (1 + \beta_k)^{\frac{1}{2}} t, \quad (3.2.11)$$

де  $a_k^{(0)}(t)$  задовольняє критерію (3.2.5) повільно змінної функції.

Таким чином, амплітуда коливань  $a_k^{(0)}(t)$ , що згенеровані  $k$ -им нелінійним осциляторним нейроном змінюється від 0 при  $t \rightarrow -\infty$  до 2 при  $t \rightarrow \infty$ .

Характерною особливістю автоколивань нейронного генератора є незалежність амплітуди від початкових умов. Крім цього, як видно з формул (3.2.10), (3.2.11), операція діагоналізації нелінійної осциляторної нейронної мережі, яка врахована параметром  $\beta_k$ , приводить до перенормування амплітуди коливань  $a_k^{(0)}(t)$  та власної частоти  $\tilde{\omega}_{0k} = \omega_{0k} (1 + \beta_k)$ . Для знаходження виразів  $a_k^{(1)}(t)$  і  $\psi_k^{(1)}(t)$  у першому наближенні ( $n=1$ ) необхідно підставити вирази (3.2.10), (3.2.11) у систему рівнянь (3.2.7). Внаслідок інтегрування отримаємо у першому наближенні вирази для  $a_k^{(1)}(t)$  і  $\psi_k^{(1)}(t)$ .

Процес ітерації припиняється, коли будуть виконуватися умови:

$$\left| \frac{a_k^{(n)}(t) - a_k^{(n-1)}(t)}{a_k^{(n)}(t)} \right| \ll \delta, \quad \left| \frac{\psi_k^{(n)}(t) - \psi_k^{(n-1)}(t)}{\psi_k^{(n)}(t)} \right| \ll \delta, \quad (3.2.12)$$

де  $\delta = 10^{-5}$ .

### 3.3. Шифрування інформації ланцюговою та кільцевою мережами з нелінійними осциляторними нейронами

Значний інтерес для сучасної нейродинаміки складає дослідження процесів шифрування, обробки та розшифрування інформації, яка передається нейронами. На перших етапах обробки сенсорної інформації вейвлет-аналіз є ефективним інструментом для дослідження інформаційної складової нейронних сигналів, що реєструються. Традиційно таке дослідження зводиться до аналізу структури точкових процесів, тобто до аналізу частотно-часової динаміки нейронних відгуків [133 – 138], у яких носіями інформації є часи генерації імпульсів (спайків), а не їх форма [139]. Механізми, що приводять до генерації спайків, частково відомі [140]. Але те, яким чином нейрони та їх ансамблі передають інформацію про навколишній світ, до цього часу практично не досліджено.

Серед актуальних проблем криптографії є розробка математичної моделі, що забезпечить високий ступінь захищеності інформації завдяки максимальній зміні структури вхідного інформаційного сигналу.

У цьому параграфі на основі нелінійних осциляторних нейронів виду Ван-Дер-Поля з топологією у вигляді «ланцюжка» та «кільця» запропонована модель шифрування інформації завдяки максимального перетворення структури (форми, амплітуди, частоти та фази) вхідного інформаційного сигналу. Такого перетворення структури сигналу можна досягнути за допомогою нелінійного осциляторного нейрона з власною динамікою, системи нелінійних осциляторних нейронів з власною динамікою або зміни топології нелінійних осциляторних нейронів. У наближенні диполь – дипольної взаємодії нелінійних осциляторних нейронів значення вагових синаптичних коефіцієнтів можна змінювати завдяки топології розміщення нелінійних нейронів.

У роботі [141] було проведене, у наближенні Ван-дер-Поля, комп'ютерне моделювання динаміки нейрона при дії на нього зовнішнього постійного сигналу без урахування порогового ефекту нейрона. На відміну від роботи [141] у цьому дослідженні розглядається система, взаємопов'язаних ваговими синаптичними зв'язками  $\lambda_{jk}$ , нелінійних осциляторних нейронів виду Ван-дер-Поля, при дії на

них нестационарних вхідних сигналів  $V_k(t)$  з ваговими коефіцієнтами синаптичних зв'язків  $\lambda_{jk}$  з  $k$ -им нейроном і з урахуванням порогового ефекту нейрона.

Розглянемо процеси шифрування вхідного інформаційного сигналу окремим нелінійним осциляторним нейроном з урахуванням його порогового ефекту та системою нелінійних осциляторних нейронів, взаємопов'язаних ваговими синаптичними коефіцієнтами  $\lambda_{jk}$  з конфігураційною топологією у вигляді «ланцюжка» та «кільця».




Рис. 3.3.1. Схематичне зображення ланцюгової мережі нелінійних нейронів з одностороннім зв'язком вагових коефіцієнтів  $\lambda_{k,k-1}$




Рис. 3.3.2. Схематичне зображення кільцевої мережі нелінійних нейронів з одностороннім (а) та двостороннім (б) зв'язком вагових коефіцієнтів

Для ілюстрації розглянемо шифрування інформації окремим сенсорним нелінійним осциляторним  $k$ -м нейроном та мережею нелінійних нейронів, взаємопов'язаних у вигляді «ланцюжка» (Рис. 3.3.1) та «кільця» (Рис. 3.3.2), які описуються нелінійним рівнянням (3.3.1) або системою  $N$  нелінійних рівнянь (3.3.2) відповідно:

$$\ddot{X}_k + \mu_k [X_k^2 - p_k^2(N_{0k}; N_{ck})] \dot{X}_k + \omega_{0k}^2 X_k = V_k(t), \quad (3.3.1)$$

$$\ddot{X}_k + \mu_k \left\{ [X_k + \sum_{j=1}^N \lambda_{jk} X_j]^2 - p_k^2(N_{0k}; N_{ck}) \right\} \dot{X}_k + \omega_{0k}^2 [X_k + \sum_{j=1}^N \lambda_{jk} X_j] = V_k(t), \quad (3.3.2)$$

де  $k = 1, 2, 3, \dots, N$ ;  $V_k(t) = \begin{cases} V_1(t), k = 1 \\ X_{k-1}(t), k = 2, 3, 4, 5, \dots, N \end{cases}$ ;  $\lambda_{jk} = 0$  при  $j = k$ .

$V_1(t)$  – несучий інформаційний сигнал, який поступає на перший нелінійний нейрон мережі нейронів, взаємопов'язаних ваговими синаптичними коефіцієнтами  $\lambda_{jk}$ ;

$X_{k-1}(t)$  – спотворений  $(k-1)$  нейронами несучий інформаційний сигнал, що поступає на  $k$ -й нелінійний нейрон;

$p_k^2(N_{0k}; N_{ck}) = p_{0k}^2 \tanh\left(\frac{N_{0k} - N_{ck}}{\sigma_k^2}\right)$  – параметр амплітуди  $k$ -го нейрона;

$N_{0k}$ ,  $N_{ck}$ ,  $\sigma_k^2$  – число імпульсів, які приходять на  $k$ -й нейрон, порогове значення імпульсів  $k$ -го нейрона та дисперсія відповідно;

$\omega_{0k}^2$  – власна частота  $k$ -го нелінійного осциляторного нейрона;

$V_k(t)$  – вхідний нестационарний сигнал, який поступає на  $k$ -й нейрон.

Запишемо систему нелінійних рівнянь (3.3.2) для ланцюгової мережі (Рис. 3.3.1), яка складається з трьох синаптично зв'язаних, ваговими коефіцієнтами  $\lambda_{jk}$ , нелінійних осциляторних нейронів

$$\begin{cases} \ddot{\tilde{X}}_1 + \mu_1 [\tilde{X}_1^2 - p_1^2(N_{01}; N_{c1})] \dot{\tilde{X}}_1 + \omega_{01}^2 \tilde{X}_1 = V_1(t) \\ \ddot{\tilde{X}}_2 + \mu_2 [\tilde{X}_2^2 - p_2^2(N_{02}; N_{c2})] \dot{\tilde{X}}_2 + \omega_{02}^2 \tilde{X}_2 = X_1(t), \\ \ddot{\tilde{X}}_3 + \mu_3 [\tilde{X}_3^2 - p_3^2(N_{03}; N_{c3})] \dot{\tilde{X}}_3 + \omega_{03}^2 \tilde{X}_3 = X_2(t) \end{cases} \quad (3.3.3)$$

де  $\tilde{X}_1 = X_1 + \lambda_{21} X_2$ ,  $\tilde{X}_2 = X_2 + \lambda_{12} X_1 + \lambda_{32} X_3$ ,  $\tilde{X}_3 = X_3 + \lambda_{23} X_2$ .



Розв'язок рівняння (3.3.1) знаходимо методом Крилова-Боголюбова-Митропольського [130] і методом послідовних наближень у вигляді

$$X_k^{(n)}(t) = a_k^{(n)}(t) \sin \psi_k^{(n)}(t), \quad (3.3.4)$$

де  $n = 1, 2, 3, \dots, N$  – номер ітерації;

$$\psi_k^{(n)}(t) = \omega_{0k} t + \varphi_k^{(n)}(t), \quad (3.3.5)$$

де  $a_k^{(n)}(t)$  і  $\varphi_k^{(n)}(t)$  – функції часу, які добираються так, щоб співвідношення (3.3.4) задовольняло рівняння (3.3.5). Крім цього накладаємо умову, що  $a_k^{(n)}(t)$  є повільно змінна функція, тобто

$$\lim_{t \rightarrow \infty} \frac{a_k^{(n)}(p_k \mu_k t)}{a_k^{(n)}(p_k t)} = 1. \quad (3.3.6)$$

Але оскільки функцій є дві  $a_k^{(n)}(t)$  і  $\psi_k^{(n)}(t)$ , а рівняння одне, то ця умова неоднозначно визначає функції. Будемо вимагати, щоб виконувалась також умова

$$\dot{X}_k^{(n)} = \omega_{0k} a_k^{(n)}(t) \cos \psi_k^{(n)}(t), \quad (3.3.7)$$

$$\text{де } \dot{X}_k^{(n)} = \frac{dX_k^{(n)}(t)}{dt}.$$

Підставляючи (3.3.4) в (3.3.1) і враховуючи умову (3.3.7), отримаємо систему рівнянь для  $a_k^{(n)}(t)$  і  $\varphi_k^{(n)}(t)$ :

$$\begin{cases} \frac{da_k^{(n)}(t)}{dt} = -a_k^{(n-1)}(t) \mu_k \left[ (a_k^{(n-1)})^2 \sin^2 \psi_k^{(n-1)}(t) - p_k^2(N_{0k}; N_{ck}) \right] \cos^2 \psi_k^{(n-1)}(t) + V_k(t) \cos \psi_k^{(n-1)}(t) \\ \frac{d\psi_k^{(n)}(t)}{dt} = \omega_{0k} + \mu_k \left[ (a_k^{(n-1)})^2 \sin^2 \psi_k^{(n-1)}(t) - p_k^2(N_{0k}; N_{ck}) \right] \sin \psi_k^{(n-1)}(t) \cos \psi_k^{(n-1)}(t) - \frac{V_k(t) \sin \psi_k^{(n-1)}(t)}{a_k^{(n-1)}(t)}. \end{cases} \quad (3.3.8)$$

Усереднимо праву частину системи рівнянь (3.3.8) за період  $2\pi$  при  $V_k(t) = 0$  за правилом [130]:

$$\langle \Phi \rangle = \frac{1}{2\pi} \int_0^{2\pi} \Phi(\psi_k^{(n)}) d\psi_k^{(n)}. \quad (3.3.9)$$

У нульовому наближенні вирази для  $a_k^{(0)}(t)$  і  $\psi_k^{(0)}(t)$  знаходимо з такої системи рівнянь:

$$\frac{da_k^{(0)}(t)}{dt} = A(a_k^{(0)}(t)), \quad \frac{d\psi_k^{(0)}(t)}{dt} = B(a_k^{(0)}(t)), \quad (3.3.10)$$

$$\text{де } A(a_k^{(0)}(t)) = -a_k^{(0)}(t)\mu_k \left( \frac{(a_k^{(0)})^2}{8} - \frac{p_k^2}{2} \right), \quad B(a_k^{(0)}(t)) = \omega_{0k}.$$

Інтегруючи рівняння (3.3.10), отримаємо в нульовому наближенні вирази для  $a_k^{(0)}(t)$  і  $\psi_k^{(0)}(t)$ :

$$a_k^{(0)}(t) = \frac{2p_k}{\sqrt{1 + e^{-p_k^2 \mu_k t}}}, \quad (3.3.11)$$

$$\psi_k^{(0)}(t) = \omega_{0k} t, \quad (3.3.12)$$

де  $a_k^{(0)}(t)$  задовольняє критерію (3.3.6) повільно змінної функції.

Для знаходження виразів  $a_k^{(1)}(t)$  і  $\psi_k^{(1)}(t)$  у першому наближенні ( $n=1$ ) необхідно підставити вирази (3.3.11), (3.3.12) у систему рівнянь (3.3.8). Внаслідок інтегрування отримаємо у першому наближенні вирази для  $a_k^{(1)}(t)$  і  $\psi_k^{(1)}(t)$ .

Процес ітерації припиняється, коли будуть виконуватися умови:

$$\left| \frac{a_k^{(n)}(t) - a_k^{(n-1)}(t)}{a_k^{(n)}(t)} \right| \ll \delta, \quad \left| \frac{\psi_k^{(n)}(t) - \psi_k^{(n-1)}(t)}{\psi_k^{(n)}(t)} \right| \ll \delta, \quad (3.3.13)$$

де  $\delta = 10^{-5}$ .

Систему трьох нелінійних рівнянь (3.3.3) розв'язуємо методом Крилова-Боголюбова-Митропольського [130] і методом послідовних наближень. За нульове наближення приймаємо розв'язки  $X_k^{(0)}(t)$  ( $k=1,2,3$ ) нелінійної системи (3.3.3), знайдені без урахування вагових синаптичних  $\lambda_{jk}$  зв'язку між  $j$ -м та  $k$ -м нейронами. Для знаходження розв'язків системи нелінійних рівнянь (3.3.3) у наступних ітераціях підставляємо вирази розв'язків попереднього наближення у доданки, які містять вагові синаптичні коефіцієнти  $\lambda_{jk}$  системи рівнянь (3.3.3).

Для модельного прикладу у цій задачі зовнішній нестационарний сигнал  $V_1(t)$  вибираємо у вигляді суми  $N$  простих нестационарних сигналів, кожний з яких центрований в точці  $t = t_L$  і характеризується системою параметрів  $M_L$  [142]

$$V_1(t) = \sum_{L=0}^{N-1} \tilde{\lambda}_{L1} v_{L1}(t - t_L) + \tilde{\lambda}_{01}^*. \quad (3.3.14)$$

Підбираючи систему параметрів  $M_L$ , можна сконструювати математичну модель складного нестационарного сигналу  $V_1(t)$ , спектральні властивості якого змінюються в часі. Запропонована математична модель зовнішнього нестационарного сигналу  $V_1(t)$  буде відображати динаміку реального сигналу, що характеризує певний фізичний (біологічний) процес. Прикладом простого нестационарного сигналу  $v_{L1}(t-t_L)$  є вираз:

$$v_{L1}(t-t_L) = \frac{1}{2\tau_L\sqrt{\pi}} \exp\left[-\frac{(t-t_L)^2}{4\tau_L^2}\right] \cos(\omega_L(t-t_L) + \alpha_L), \quad (3.3.15)$$

який представляє собою добуток огинаючої гаусовської форми на осцилюючу функцію і описується системою п'яти параметрів  $M_L$

$$M_L = (\tilde{\lambda}_{L1}, \omega_L, t_L, \tau_L, \alpha_L), \quad (3.3.16)$$

де  $\tilde{\lambda}_{L1}$  – вагові коефіцієнти зв'язків вхідних сигналів  $v_{11}, \dots, v_{N1}$  з окремим першим нейроном, що не взаємодіє з іншими нейронами;  $\tilde{\lambda}_{01}^*$  – ваговий коефіцієнт зв'язку сигналу зсуву з першим окремим нейроном. У випадку мережі взаємопов'язаних нелінійних нейронів – вагові коефіцієнти зв'язків між  $k-1$ -м та  $k$ -м нейронами становлять  $\lambda_{k,k-1}$ ;  $\omega_L = 2\pi f_L$  – зовнішня частота несучих коливань в герцах (Hz);  $t_L$  – центр локалізації сигналу за часом в секундах,  $\tau_L$  – характерний часовий інтервал локалізації сигналу в секундах,  $\alpha_L$  – початкова фаза в радіанах.

Формула (3.3.14) описує суперпозицію вхідних сигналів (3.3.15), включаючи сигнал зсуву, що надходять з ваговими коефіцієнтами  $\tilde{\lambda}_{L1}$  на суматор окремого першого нейрона (вхідний оператор  $\hat{f}_{in}$ ). Вхідний оператор  $\hat{f}_{in}$  перетворює зважені ваговими коефіцієнтами  $\tilde{\lambda}_{L1}$  входи і подає їх на оператор активації  $\hat{f}_a$  (Рис. 3.3.3). Для сенсорного окремого нелінійного  $k$ -го осциляторного нейрона оператор активації  $\hat{f}_a$  має вигляд:

$$\hat{f}_a = \frac{d^2}{dt^2} + \mu_k \left[ X_k^2 - p_k^2(N_{0k}; N_{ck}) \right] \frac{d}{dt} + \omega_{0k}^2, \quad (3.3.17)$$

де  $k = 1, 2, 3, \dots, N$ .




Рис. 3.3.3. Структура штучного нелінійного осциляторного окремого нейрона.

Вихідний сигнал нелінійного осциляторного нейрона  $X_1(t)$  (Рис. 3.3.3) являє собою перетворений вихідним оператором  $\hat{f}_{out}$  вихідний сигнал оператора активації. Вихідний оператор  $\hat{f}_{out}$  є необхідний для представлення стану нейрона у бажаній області значень. У більшості робіт цей оператор не виділяють, а під вихідним сигналом нейрона розуміють сигнал після оператора активації  $\hat{f}_a$ . Однак під час аналізу й синтезу штучних нейронних мереж, які мають різні активаційні функції з різними областями значень й областями визначення виникає необхідність урахування оператора виходу. Отже, нелінійний оператор перетворення вектора вхідних сигналів  $X_{N-1}(t)$  у ланцюжку (кільці) (Рис. 3.3.1 та Рис. 3.3.2) у вектор вихідного сигналу  $X_N(t)$  можна записати у вигляді:

$$X_N(t) = \hat{f}_{out}(\hat{f}_a(\hat{f}_{in}(X_{N-1}(t), \lambda_{LN}))). \quad (3.3.18)$$

Підбираючи різні комбінації параметрів  $M_L = (\tilde{\lambda}_{L1}, \omega_L, t_L, \tau_L, \alpha_L)$ , можна змінювати криптостійкість нейро-криптосистеми.

На Рис. 3.3.4 зображено графік зовнішнього нестационарного сигналу  $V_1(t)$  (3.3.14), який представляє собою суперпозицію п'яти ( $N = 5, L = 0, 1, 2, 3, 4$ ) простих нестационарних сигналів (3.3.15), що подаються на сенсорний нелінійний осциляторний окремий нейрон з однаковими ваговими коефіцієнтами ( $\tilde{\lambda}_{L1} = 4$ )

зв'язків вхідних сигналів  $v_{11}, \dots, v_{N1}$  з окремим нейроном і однаковим часовим інтервалом локалізації  $\tau_L = 0,5$  с. На інтервалі часу  $0 \leq t \leq 8$  с вершини гаусовських піків розміщені за часом рівно віддалено  $t_L = 1 + L$ . При цьому частоти  $\omega_L$  кожного простого зовнішнього нестационарного сигналу  $v_{L1}(t - t_L)$  (3.3.15) лінійно зростають за законом  $f_L = \frac{4L}{5}$  (Hz). Цей графік разом з графіком частотної модуляції (Рис. 3.3.5) показує моменти виникнення локальних частот і відображає перехідні етапи перебудови частотного спектру сигналу. Закон зміни миттєвої частоти  $\hat{\omega}_k(t) = \frac{d\Psi_k^{(n)}(t)}{dt}$  (Рис. 3.3.5) несучого інформаційного сигналу описується другим рівнянням системи рівнянь (3.3.8).




Рис. 3.3.4. Морфологія зовнішнього нестационарного сигналу  $V_1(t)$  (3.3.14) у вигляді суперпозиції п'яти ( $N=5$ ) простих нестационарних сигналів  $v_{L1}(t - t_L)$  (3.3.15).




Рис. 3.3.5. Часова залежність миттєвої частоти несучого інформаційного сигналу  $V_1(t)$  (3.3.14) у вигляді суперпозиції п'яти ( $N=5$ ) простих нестационарних сигналів;  $v_{L1}(t - t_L)$  (3.3.15), що поступають на окремий нелінійний осциляторний нейрон при значеннях параметрів  $M_L = (4; 8\pi L/5; L+1; 0,5; 0)$ ,  $p_k = 0,4$  та  $\mu_k = 0,1$ ,

$$\omega_{0k} = 2$$




Рис. 3.3.6. Графік морфології сигналу на виході нелінійного осциляторного окремого нейрона  $X_1(t)$  при подачі на нього суперпозиції п'яти ( $N=5$ ) простих нестационарних сигналів  $v_{L1}(t - t_L)$  (3.3.15) при значеннях параметрів

$$M_L = (4; 8\pi L/5; L+1; 0,5; 0), p_k = 0,4 \text{ та } \mu_k = 0,1, \omega_{0k} = 2$$

Порівняльний аналіз морфології зовнішнього інформаційного сигналу  $V_1(t)$  (Рис. 3.3.4) на вході нелінійного осциляторного окремого нейрона з морфологією сигналу на виході окремого нейрона  $X_1(t)$  (Рис. 3.3.6) показує, що структура вхідного сигналу  $V_1(t)$  суттєво змінилася завдяки взаємодії власної динаміки нелінійного нейрона з динамікою, зумовленою зовнішньою дією на нього сигналу  $V_1(t)$ .

На Рис. 3.3.7 та Рис. 3.3.8 зображено графіки зовнішніх нестационарних сигналів  $V_1(t)$  у вигляді суперпозиції прямокутних імпульсів (3.3.19) (Рис. 3.3.7) та одинарного прямокутного імпульсу (Рис. 3.3.8), які подаються на вхід окремого нелінійного осциляторного нейрона.

$$V_1(t) = \sum_{L=0}^{N-1} \tilde{\lambda}_{L1} [\theta(t - ((L+1)t_a + Lt_b)) - \theta(t - (L+1)(t_a + t_b))] + \tilde{\lambda}_{01}^*, \quad (3.3.19)$$

де  $\theta$  – функція Хевісайда;  $\theta(t - ((L+1)t_a + Lt_b)) - \theta(t - (L+1)(t_a + t_b)) = 0$ ,

якщо  $t < ((L+1)t_a + Lt_b) - \theta(t - (L+1)(t_a + t_b))$

і  $\theta(t - ((L+1)t_a + Lt_b)) - \theta(t - (L+1)(t_a + t_b)) = 1$ ,

якщо  $t \geq ((L+1)t_a + Lt_b) - \theta(t - (L+1)(t_a + t_b))$ ,  $L = \overline{0, N-1}$ .

Для підвищення ступеня захисту інформації несучого сигналу від несанкціонованого втручання у процесі передачі сигналу по мережі нелінійних нейронів (Рис. 3.3.1, Рис. 3.3.2) необхідно період  $T_L = t_a + t_b$  слідування кожного наступного прямокутного імпульсу задавати у вигляді нелінійної функції  $\frac{\varphi(L+1)}{N}$ , тобто  $T_L = t_a + t_b = \frac{\varphi(L+1)}{N}$ , де  $\varphi(L+1)$  – деяка нелінійна функція,  $N$  – число періодів.




Рис. 3.3.7. Вхідний інформаційний несучий сигнал  $V_1(t)$  у вигляді суперпозиції прямокутних імпульсів з шириною імпульсу 4 с та періодом  $T = 6$  с, що поступає на нелінійний нейрон.






Рис. 3.3.8. Вхідний інформаційний прямокутний несучий сигнал  $V_1(t)$  з шириною імпульсу 2 с, що поступає на окремий нелінійний осциляторний нейрон.



На *Рис. 3.3.9* зображено графік частотної модуляції. Цей показує моменти виникнення локальних частот і відображає перехідні етапи перебудови частотного спектру сигналу.




*Рис. 3.3.9.* Частотна модуляція інформаційного сигналу  $V_1(t)$  (*Рис. 3.3.8*), що поступає на окремий нелінійний осциляторний нейрон при наступних значеннях параметрів:  $p_k = 0,4$  та  $\mu_k = 0,1$ ,  $\omega_{0k} = 2$ .



*Рис. 3.3.10.* Графік морфології сигналу на виході нелінійного осциляторного окремого нейрона  $X_1(t)$  при подачі на нього прямокутного імпульсу (*Рис. 3.3.8*) при значеннях параметрів  $\tilde{\lambda}_{L1} = 1$ ;  $t_a = 2$  с;  $t_b = 2$  с.

На *Рис. 3.3.11* представлено графіки морфології сигналу на виході окремого нелінійного осциляторного нейрона  $X_1(t)$ , яка визначається характером взаємодії власної динаміки нейрона з частотою  $\omega_{0k} = 0.2\pi$  і динаміки, зумовленої зовнішньою дією  $v_{L1}(t - t_L)$  (3.3.15).



*Рис. 3.3.11. Графік морфології сигналу на виході окремого нелінійного осциляторного нейрона  $X_1(t)$  при значеннях параметрів  $M_L = (3; 4\pi; 12; 3; 0)$  ;*

$$p_k = 0,4 \text{ та } \mu_k = 0,1, \omega_{0k} = 0,2\pi$$

При взаємодії зовнішнього сигналу  $v_{L1}(t - t_L)$  (3.3.15) (який має параметри  $M_L = (3; 4\pi; 12; 3; 0)$ ) з власною динамікою нелінійного осциляторного нейрона  $\omega_{0k} = 4\pi$  спостерігається різке зростання амплітуди вихідного сигналу  $X_1(t)$  (*Рис. 3.3.12*) порівняно з вихідним сигналом на *Рис. 3.3.11*. Тобто має місце резонансний ефект при співпадінні частоти зовнішнього сигналу з власною частотою коливань нелінійного нейрона, ( $\omega_L = \omega_{0k}$ ).




Рис. 3.3.12. Графік морфології сигналу на виході нелінійного осциляторного окремого нейрона  $X_1(t)$  у випадку резонансного ефекту при значенні параметрів

$$M_L = (3; 4\pi; 12; 3; 0) ; p_k = 0,4 \text{ та } \mu_k = 0,1, \omega_{0k} = 4\pi$$

На вхід лінійного ланцюжка, що складається з трьох взаємопов'язаних синаптичними зв'язками  $\lambda_{k,k-1}$  нелінійних нейронів (Рис. 3.3.1), подається гармонічний сигнал  $V_1(t) = V_0 \cos \omega t$ . Вейвлет-аналіз [143, 144] морфології сигналу на виході ланцюгової мережі, що складається з трьох нелінійних осциляторних нейронів (Рис. 3.3.13), показує, що структура вихідного сигналу на виході лінійної мережі  $X_3(t)$  за формою, амплітудою (Рис. 3.3.13) та часовою залежністю миттєвої частоти несучого інформаційного сигналу (Рис. 3.3.14) має вищий ступінь стохастичності ніж морфологія сигналу на виході окремого нейрона. Це пов'язано з тим, що на характер структури (форми, амплітуди та частотної модуляції) інформаційного сигналу на виході ланцюжка  $X_3(t)$  впливають не тільки синаптичні взаємозв'язки між нелінійними осциляторними нейронами, але й взаємодія власної динаміки окремого нейрона з динамікою вхідного сигналу, що поступає на цей нейрон.




Рис. 3.3.13. Графік морфології сигналу на виході лінійної ланцюгової мережі (Рис. 3.3.1), що складається з трьох нелінійних осциляторних нейронів при подачі на нього гармонічного сигналу  $V_1(t) = V_0 \cos \omega t$  при значеннях параметрів:  $V_0 = 1$ ;  $\tilde{\omega} = 3$ ;  $\omega_{01} = \omega_{02} = \omega_{03}$ ;  $p_1 = 0,4$ ;  $p_2 = 0,3$ ;  $p_3 = 0,2$ ;  $\mu_1 = 0,1$ ;  $\mu_2 = 0,2$ ;  $\mu_3 = 0,4$ ;  $\lambda_{21} = 0,5$ ;  $\lambda_{32} = 0,4$ .




Рис. 3.3.14. Частотна модуляція інформаційного сигналу на виході лінійної ланцюгової мережі (Рис. 3.3.2), що складається з трьох нелінійних осциляторних нейронів при подачі на нього гармонічного сигналу  $V_1(t) = V_0 \cos \omega t$  при значеннях параметрів:  $V_0 = 1$ ;  $\tilde{\omega} = 3$ ;  $\omega_{01} = \omega_{02} = \omega_{03}$ ;  $p_1 = 0,4$ ;  $p_2 = 0,3$ ;  $p_3 = 0,2$ ;  $\mu_1 = 0,1$ ;  $\mu_2 = 0,2$ ;  $\mu_3 = 0,4$ ;  $\lambda_{21} = 0,5$ ;  $\lambda_{32} = 0,4$ .

Для того щоб розшифрувати структуру вихідного сигналу  $X_N$  після  $N$ -го нелінійного нейрона, необхідно підставити послідовно  $N$  разів вихідні сигнали після кожного попереднього нейрона  $X_N$  в диференційне рівняння для  $X_{N-1}$ . Точність розшифрування сигналу становить  $\varepsilon_N = 1 - (1 - \delta)^N$ , де  $\delta = 10^{-5}$ ,  $N$  – число нелінійних нейронів, тобто  $\hat{f}_{in}^{-1}(\hat{f}_a^{-1}(\hat{f}_{out}^{-1}X_N(t))) = X_{N-1}(t)$ .

Отже, отримані результати дозволяють висунути гіпотезу про те, що процес шифрування інформації окремим нейроном або нелінійною нейронною мережею може розглядатися в термінах частотної модуляції [145, 146], оскільки в радіофізиці відомо, що частотна модуляція є одним із способів передачі інформації, і цілком ймовірно, що вона представляє собою один із варіантів кодування інформації нейронами.

### **3.4. Розпізнавання спектральної інформації на основі синтезу модифікованих осциляторних нейронних мереж та голографічних методів обробки даних**

У сучасних умовах національна безпека країни переважно визначається ступенем впровадження досягнень в інформаційній та технологічній областях. Одним із основних способів досягнення ефективного функціонування системи керування в швидкозмінному середовищі є підвищення рівня інформаційної підтримки процесів прийняття рішень завдяки інтеграції інформаційних технологій в автоматизовані системи керування. Кількість оперативної вхідної інформації постійно зростає, що вимагає використання автоматизованих засобів обробки і аналізу мультиспектральних образів. При створенні сучасних автоматизованих систем керування та систем інформаційної підтримки прийняття рішень виникає проблема автоматизації розпізнавання спектральних образів на основі даних аерокосмічної розвідки. Існуючі класичні методи розпізнавання образів не забезпечують відповідного рівня оперативності та надійності розв'язку зазначених задач. Для вирішення проблеми автоматизації розпізнавання спектральних образів останнім часом застосовуються досягнення суміжних

областей науки: штучні нейронні мережі (ШНМ) [39], генетичні алгоритми [147], а також методи, які базуються на представленні теорії нечітких множин [39].

Нечітка логіка передбачає підвищені вимоги до обчислювальної потужності й об'єму пам'яті процесора. Для реалізації цих вимог використовуються оптичні інформаційні технології [148]. Перспективним напрямком є розробка нейро-нечітких пристроїв, що поєднують гнучкість і адекватність нечіткої логіки з обчислювальною потужністю і здатністю до самонавчання ШНМ, на основі цифрової голографії [149].

У роботах [150] був запропонований підхід до розв'язку задач розпізнавання мультиспектральних образів, який базується на синтезі ШНМ і голографічних методів обробки даних. У синтезованих ШНМ з голографічними методами, автори робіт [150], використовували тільки статичні моделі нейронів [39, 151]. У цьому підрозділі розглядається задача розпізнавання мультиспектральних образів на основі синтезу осциляторної нейронної мережі і цифрової голографії.

Для створення та розпізнавання цифрового голографічного образу нейроголографічною мережею використовується генерація коливань нелінійними осциляторними нейронами як опорна хвиля, яка накладається з хвильовим фронтом об'єктної хвилі образу. Генерація опорних сигналів з набором власних частот може бути забезпечена тільки штучною нейронною мережею з нелінійними осциляторними нейронами. Штучна нейронна мережа з нелінійними осциляторними нейронами за своїми функціональними властивостями подібна до мережі нейронів мозку людини [125, 152].

Задачі розпізнавання мультиспектральних образів ШНМ з осциляторними нейронами забезпечать високу точність виявлення в режимі реального часу спектрів зовнішніх об'єктів.

Існування аналогій між математичними обґрунтуваннями ШНМ, нечіткої логіки та Фур'є-голографією відкриває перспективи для реалізації методів розпізнавання образів на базі єдиного нейромережевого підходу.

Як було зазначено у розділі 2 параграф 2.2., будь-яку неперервну функцію  $\tilde{F}(\vec{V})$  від  $n$  змінних  $\vec{V} = (V_1, V_2, \dots, V_n)$  з заданою точністю  $\varepsilon > 0$  можна апроксимувати тришаровою діагоналізованою нейронною мережі з одним прихованим шаром та однією операцією агрегування (модифікована теорема Хехт-Нільсена) [94].

Архітектура модифікованої осциляторної нейронної мережі з нелінійними осциляторними нейронами отримується із архітектури класичної тришарової нейромережі способом діагоналізації матриці синаптичних зв'язків [104] (Рис. 3.4.1). Спосіб діагоналізації матриці синаптичних зв'язків приведений у розділі 2 параграф 2.1, а осциляторна мережа з нелінійними осциляторними нейронами описана у розділі 3 параграф 3.2.




Рис. 3.4.1. Схематичне зображення тришарової нейронної мережі прямого поширення з діагоналізованими ваговими коефіцієнтами синаптичних зв'язків  $\lambda_{ij}$ .

Тоді рівняння модифікованої осциляторної нейронної мережі прийме вигляд:

$$\tilde{F}_\varepsilon(V_1(\omega_1), V_2(\omega_2), \dots, V_n(\omega_n)) = \sum_{j=1}^m W_j \cdot g_j \left[ \beta_j V_j(\omega_j) + \theta_j \right], \quad (3.4.1)$$

$$\ddot{g}_j + \mu_j \left\{ g_j^2 [1 + \beta_j]^2 - p_j^2(N_{0j}; N_{cj}) \right\} \dot{g}_j + \omega_{0j}^2 [g_j(1 + \beta_j)] = V_j(t), \quad (3.4.2)$$

де  $g_j[\beta_j V_j(\omega_j) + \theta_j]$  – функція активації  $j$ -го осциляторного нейрона;

$p_j^2(N_{0j}; N_{cj}) = p_{0j}^2 \tanh\left(\frac{N_{0j} - N_{cj}}{\sigma_j^2}\right)$  – параметр амплітуди  $j$ -го нейрона;

$N_{0j}, N_{cj}, \sigma_j^2$  – число імпульсів, які приходять на  $j$ -й нейрон, порогове значення імпульсів  $j$ -го нейрона та дисперсія відповідно;

$\omega_{0j}^2$  – власна частота  $j$ -го нелінійного осциляторного нейрона;

$V_j(t)$  – вхідний нестационарний сигнал, який поступає на  $j$ -й нейрон.

Порівняльний аналіз формули (3.4.1) з рівнянням модифікованого формального нейрона (МФН) [39]

$$y = \tilde{F}_{MFN} = g \left( \sum_{j=1}^m A S_j(V_j) \right) \quad (3.4.3)$$

показує, що синаптична функція осциляторних нелінійних нейронів  $S_j(V_j(\omega_j))$  визначається добутком синаптичної ваги  $W_j$  на функцію активації  $g_j[\beta_j V_j(\omega_j) + \theta_j]$ , тобто

$$S_j(V_j(\omega_j)) = W_j \cdot g_j[\beta_j V_j(\omega_j) + \theta_j], \quad (3.4.4)$$

тоді як в роботі [39] синаптична функція  $S_j(V_j)$  вибиралась у вигляді сигмоїдальної або гаусівської.

Функцію  $F$  від  $n$  змінних  $\vec{V} = (V_1, V_2, \dots, V_n)$  з достатньою точністю також можна апроксимувати за допомогою  $n$  рядів Фур'є [150]

$$F(V_1(\omega_1), V_2(\omega_2), \dots, V_n(\omega_n)) = \sum_{i=1}^n \left( \sum_{j=1}^m c_j \phi_j(V_i(\omega_i)) \right) = \sum_{i=1}^n (\gamma_i(V_i(\omega_i))), \quad (3.4.5)$$

де  $\gamma_i(V_i(\omega_i)) = \sum_{j=1}^m c_j \phi_j(V_i(\omega_i))$  – ряд Фур'є;  $\phi_j(V_i(\omega_i))$  – базисні функції;

$c_j$  – спектральні коефіцієнти (Рис. 3.4.2).



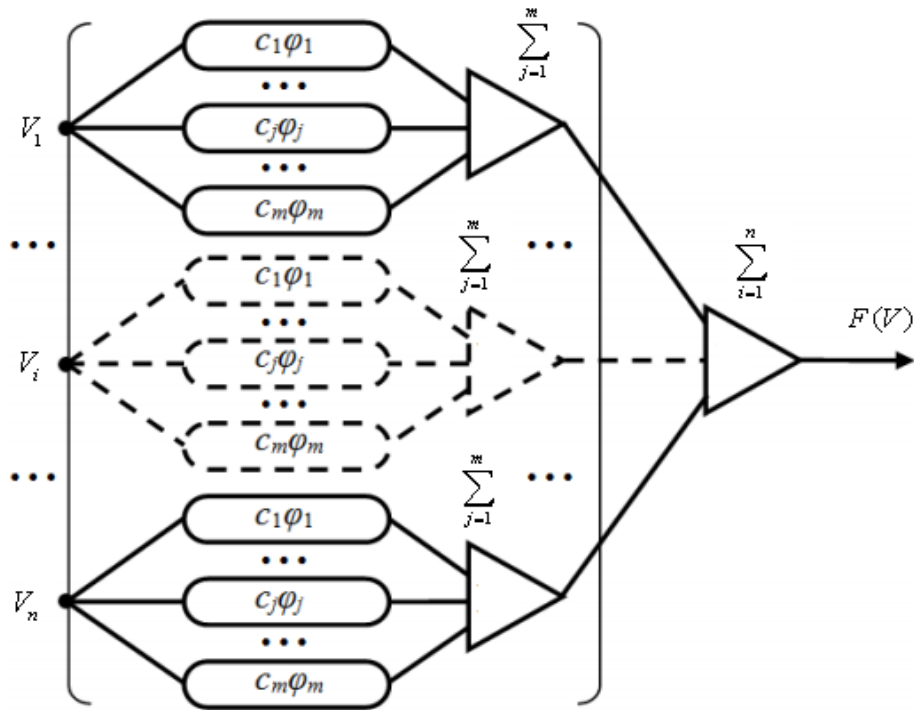


Рис. 3.4.2. Функціональна схема апроксимуючої функції у вигляді суми  $n$  скінченних рядів Фур'є

Сприйняття зображень і внутрішнє представлення вхідних образів у нейромережі пропонується реалізувати на основі синтезу цифрових голограм в структурі нейромережі [149].

Модифікована осциляторна нейронна мережа (3.4.1), що є базовим елементом голографічної нейромережі, використовує нелінійні синаптичні функції  $S_j(V_j(\omega_j))$  та реалізує уніполярну фазифікацію вхідних сигналів.

Вираз для повнозв'язного мережевого ядра можна подати у вигляді [151]:

$$y^P = g^P \left( \sum_{j=1}^{m^P} A_j^P S_j^P \left( \dots g_j^k \left( \sum_{j=1}^{m^k} A_j^k S_j^k \left[ \sum_{i=1}^{n^d} \gamma_i^d (V_i) \right] \right) \dots \right) \right), \quad (3.4.6)$$

де  $k=1,2,\dots,P$  – номер шару нейронів в мережі;  $d$  – шар нейронів, що лежить нижче шару  $k$ ;  $S_j^k$  – синаптична функція  $j$ -го синапсу нейрона  $k$ -го шару, яка визначається співвідношенням (3.4.4);  $m^k$  – загальне число синапсів нейрона  $k$ -го шару;  $g^k$  – функції активації нейрона  $k$ -го шару. Квадратними дужками виділено шар сенсорних нейронів.

У двовимірному представленні вхідний образ в комплексній формі має вигляд  $Z_{ij} = |V_{ij}| \exp\{i\phi_{ij}^{nm}\}$ , де  $n, m$  – координати точки шару, в яку із зсувом фаз  $\phi_{ij}^{nm}$  проектується сигнал від елемента зображення шару з координатами  $i, j$ , що лежить нижче від елемента шару з координатами  $n, m$ . Тоді рівняння сенсорного нейрона (3.4.5) буде мати вигляд:

$$y_{nm} = \sum_{i=0}^{N-1} \sum_{j=0}^{M-1} Z_{ij}^{nm} \exp\{i \cdot 2\pi f^* + \phi_{ij}^{nm}\}. \quad (3.4.7)$$

Замінивши у виразі (3.4.6) ядра нейромережі сенсорного шару нейронів, що описується сумою рядів Фур'є, комплексним МФН (3.4.3) з врахуванням (3.4.4) отримаємо [123]:

$$y^P = g^P \left( \underset{j=1}{\overset{m^P}{\mathbf{A} S_j^P}} \left( \dots g_j^d \left( \underset{j=1}{\overset{(N \times M)^d}{\mathbf{A} S_j^d}} [y_{nm}^d(V_{ij})] \right) \dots \right) \right), \quad (3.4.8)$$

де  $N \times M$  – розмір голограми (в цьому випадку співпадає з розміром зображення).




Рис. 3.4.3. Голографічний портрет моноспектрального зображення об'єкту на виході сенсорного шару нейронів

Вираз (3.4.7) описує сигнал на виході сенсорного шару нейронів (Рис. 3.4.3) у вигляді цифрової голограми Фур'є [150]:

$$\Gamma_{nm} = \sum_{i=0}^{N-1} \sum_{j=0}^{M-1} Z_{ij}^{nm}(f^*) \exp\{i \cdot 2\pi f^* + \phi(r_{ij}^{nm})\}, \quad (3.4.9)$$

де  $\Gamma_{nm}$  – голографічний портрет об'єкту в площині аксонів сенсорного шару нейронів;  $f^* = (n \cdot i) / N + (m \cdot j) / M$  – частотна характеристика зображення, що розглядає нейронна мережа;  $Z_{ij}^{nm}(f^*)$  та  $\phi(r_{ij}^{nm})$  – відповідно амплітудно-частотна та фазова характеристики голограми в площині внутрішнього сенсорного шару нейронної мережі;  $N \times M$  – розмір сенсорного та аксонного полів;  $r$  – відстань між точками з координатами  $(i, j)$  та  $(n, m)$ .

Таким чином, голограми, описані співвідношенням (3.4.9) представляють собою просторовий Фур'є-спектр, і можуть бути апроксимованими комплексним модифікованим формальним нейроном (3.4.7).

### Висновки до розділу 3

1. Побудована математична модель та архітектура штучної нейронної мережі з лінійними та нелінійними осциляторними нейронами, які мають власну динаміку, для розпізнавання мультиспектральних образів на основі інформаційного резонансу. Ця математична модель враховує час релаксації нейрона після потенціалу його дії, умови резонансу та генерації коливань нелінійним нейроном залежно від співвідношення загального числа імпульсів сигналу до порогового значення, які подаються на вхід нейронів.

2. Показано, що операція діагоналізації вагових коефіцієнтів синаптичних зв'язків приводить до розпаду системи нелінійних рівнянь на окремі незалежні нелінійні рівняння.

3. На основі нелінійного перетворення вхідного інформаційного сигналу нелійними нейронами розроблено нелінійну модель шифрування вхідних інформаційних сигналів за допомогою системи взаємопов'язаних нелінійних осциляторних нейронів з топологією «ланцюжка» та «кільця», а дешифрування сигналів на виході лінійного та кільцевого ланцюжків – за допомогою оберненого оператора, що діє на вектор вихідного сигналу.

4. Встановлено, що структура вихідного сигналу на виході нелінійної мережі за формою, амплітудою та часовою залежністю миттєвої частоти несучого інформаційного сигналу має вищий ступінь стохастичності ніж морфологія сигналу на виході окремого нелінійного нейрона.

5. Встановлено існування резонансних ефектів у системі взаємопов'язаних нелінійних осциляторних нейронів з топологією «ланцюжка» і «кільця» за умови рівності частоти вхідного нестационарного сигналу та власної частоти динаміки нейрона.

6. Розроблено спосіб розпізнавання інформації за допомогою модифікованої осциляторної нейронно-голографічної мережі з діагональними синаптичними зв'язками.

## РОЗДІЛ 4. РЕЗУЛЬТАТИ КОМП'ЮТЕРНОГО ЕКСПЕРИМЕНТУ З ВИКОРИСТАННЯМ НЕЙРОННИХ МЕРЕЖ

### 4.1. Програмна реалізація розпізнавання мультиспектральних образів за допомогою осциляторної нейронної мережі

На основі моделі, розробленої у розділі 3 параграф 3.1, створено математичну модель тришарової осциляторної нейронної мережі (Рис. 3.1.1.), яка описується виразом:

$$Y = \begin{cases} 1, \text{if } \sum_{m=1}^{10} v_m * \frac{1}{1 + e^{-\beta \sum_{i=1}^5 V_{im} * \frac{\Omega_{im}^2}{2\sqrt{(\omega_{im}^2 - 4\Omega_{im}^2)^2 + 16\delta^2\Omega_{im}^2}}} - v_0 > 0 \\ 0, \text{if } \sum_{m=1}^{10} v_m * \frac{1}{1 + e^{-\beta \sum_{i=1}^5 V_{im} * \frac{\Omega_{im}^2}{2\sqrt{(\omega_{im}^2 - 4\Omega_{im}^2)^2 + 16\delta^2\Omega_{im}^2}}} - v_0 \leq 0 \end{cases}, \quad (4.1.1)$$

де  $Y$  – функція активації вихідного шару;  $V_{im}$  – зовнішній  $i$ -й сигнал ( $i = \overline{1,5}$ ), який подається з сенсорного (першого) шару, що містить 5 сенсорних нейронів на  $m$ -й нейрон прихованого (другого) шару, що містить 10 нейронів;  $\Omega_{im}$  – частота  $i$ -того зовнішнього сигналу  $V_{im}$ , що подається на  $m$ -й нейрон прихованого (другого) шару нейромережі;  $\delta$  – параметр затухання нейронів;  $\beta$  – крутизна функції активації;  $\omega_{im}$  – власна частота  $m$ -того нейрона ( $m = \overline{1,10}$ ), яка відіграє роль синаптичних зв'язків між  $i$ -им сенсорним нейроном першого шару та  $m$ -им нейроном прихованого шару;  $v_m$  – вагові коефіцієнти синаптичних зв'язків між нейронами прихованого (другого) шару та вихідного (третього) шару, який має тільки один нейрон.

Для моделі нейронної мережі (4.1.1) розроблено алгоритм навчання та програму для розпізнавання мультиспектральних образів на основі інформаційного резонансу [122].

Алгоритм навчання складається з таких кроків:

1. Ініціалізація мережі: вагові коефіцієнти і зсуви мережі приймають малі випадкові значення. Задається коефіцієнт швидкості навчання  $\eta (0 < \eta < 1)$  та максимально допустиме значення середньоквадратичної помилки навчання  $E_{\max}$ .

2. Визначаємо  $y_i$  – еталонне значення для кожного елементу навчальної

вибірки з умови інформаційного резонансу

$$y_i = \begin{cases} 1, & \left| \Omega_{im} - \frac{\omega_{im}^2}{2\sqrt{\omega_{im}^2 - 2\delta^2}} \right| \leq \varepsilon \\ 0, & \left| \Omega_{im} - \frac{\omega_{im}^2}{2\sqrt{\omega_{im}^2 - 2\delta^2}} \right| > \varepsilon \end{cases}, \text{ де}$$

$0 < \varepsilon < 1$  задане наперед.

3. Послідовно на вхід нейронної мережі подаються пари з навчальної вибірки  $(V_{im}(\Omega_{im}), y_i)$ .

4. Обчислюємо  $E = \frac{1}{2} \left[ \sum_{m=1}^{10} v_m * \frac{1}{1 + e^{-\beta \sum_{i=1}^5 V_{im} * \frac{\Omega_{im}^2}{2\sqrt{(\omega_{im}^2 - 4\Omega_{im}^2)^2 + 16\delta^2\Omega_{im}^2}}} - v_0 - y_i \right]^2$ .

5. Якщо  $E < E_{\max}$ , тоді завершуємо алгоритм навчання. Якщо  $E \geq E_{\max}$ , тоді розпочинається новий цикл навчання з переходом до 6.

6. Обчислюємо похідні  $E'(\omega_{im}), E'(v_m)$ :

$$E'(\omega_{im}) = \frac{\left( e^{-\beta \sum_{i=1}^5 \left( \frac{V_{im}\Omega_{im}^2}{2\sqrt{16\delta^2\Omega_{im}^2 + (\omega_{im}^2 - 4\Omega_{im}^2)^2}} \right)} \beta v_m V_{im} \omega_{im} \Omega_{im}^2 (\omega_{im}^2 - 4\Omega_{im}^2) \left( -v_0 - y_i + \sum_{m=1}^{10} \frac{v_m}{1 + e^{-\beta \sum_{i=1}^5 \left( \frac{V_{im}\Omega_{im}^2}{2\sqrt{16\delta^2\Omega_{im}^2 + (\omega_{im}^2 - 4\Omega_{im}^2)^2}} \right)}} \right) \right)}{\left( \left( 1 + e^{-\beta \sum_{i=1}^5 \left( \frac{V_{im}\Omega_{im}^2}{2\sqrt{16\delta^2\Omega_{im}^2 + (\omega_{im}^2 - 4\Omega_{im}^2)^2}} \right)} \right)^2 \left( 16\delta^2\Omega_{im}^2 + (\omega_{im}^2 - 4\Omega_{im}^2)^2 \right)^{\frac{3}{2}} \right)}$$

$$E'(v_m) = \frac{\left( -v_0 - y_i + \sum_{m=1}^{10} \frac{v_m}{1 + e^{-\beta \sum_{i=1}^5 \left( \frac{V_{im} \Omega_{im}^2}{2\sqrt{16\delta^2 \Omega_{im}^2 + (\omega_{im}^2 - 4\Omega_{im}^2)^2}} \right)}} \right)}{\left( 1 + e^{-\beta \sum_{i=1}^5 \left( \frac{V_{im} \Omega_{im}^2}{2\sqrt{16\delta^2 \Omega_{im}^2 + (\omega_{im}^2 - 4\Omega_{im}^2)^2}} \right)} \right)}$$

7. Після чого оновлюються вагові коефіцієнти мережі:  $\omega_{im}(t+1) := \omega_{im}(t) - \eta E'(\omega_{im}(t))$ ,  $v_m(t+1) := v_m(t) - \eta E'(v_m(t))$ ,  $t$  – номер ітерації навчання та переходимо до кроку 2.

Робота нейронної мережі описана наступною діаграмою діяльності (Рис. 4.1.1).

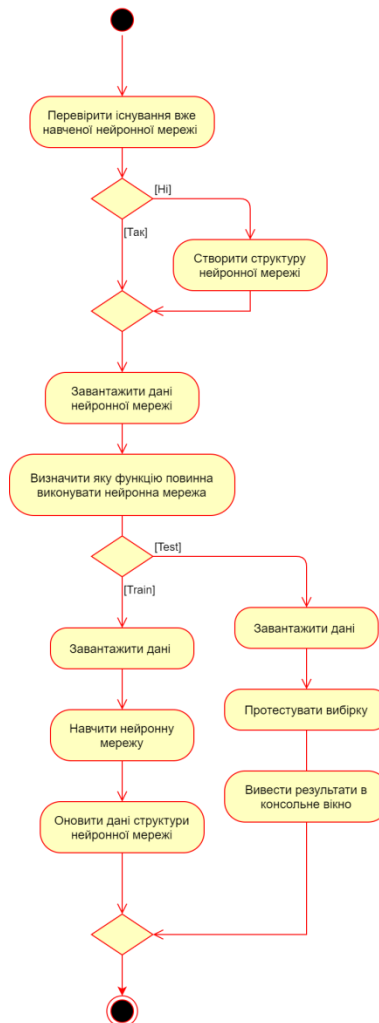


Рис. 4.1.1. Діаграма діяльності осциляторної нейронної мережі

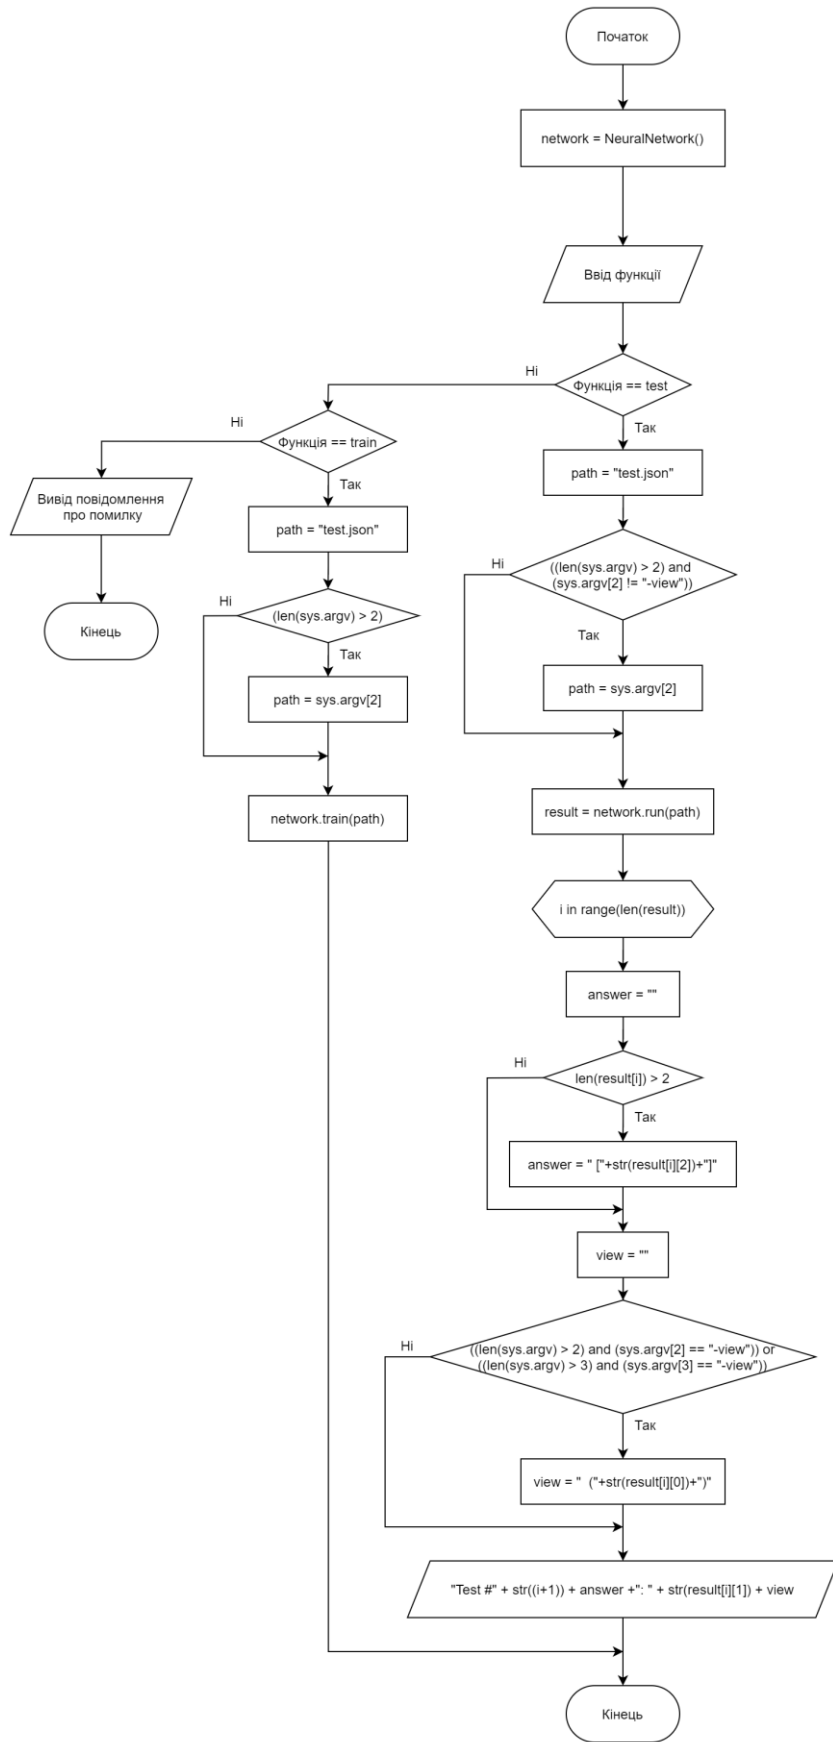


Рис. 4.1.2. Блок-схема алгоритму програми



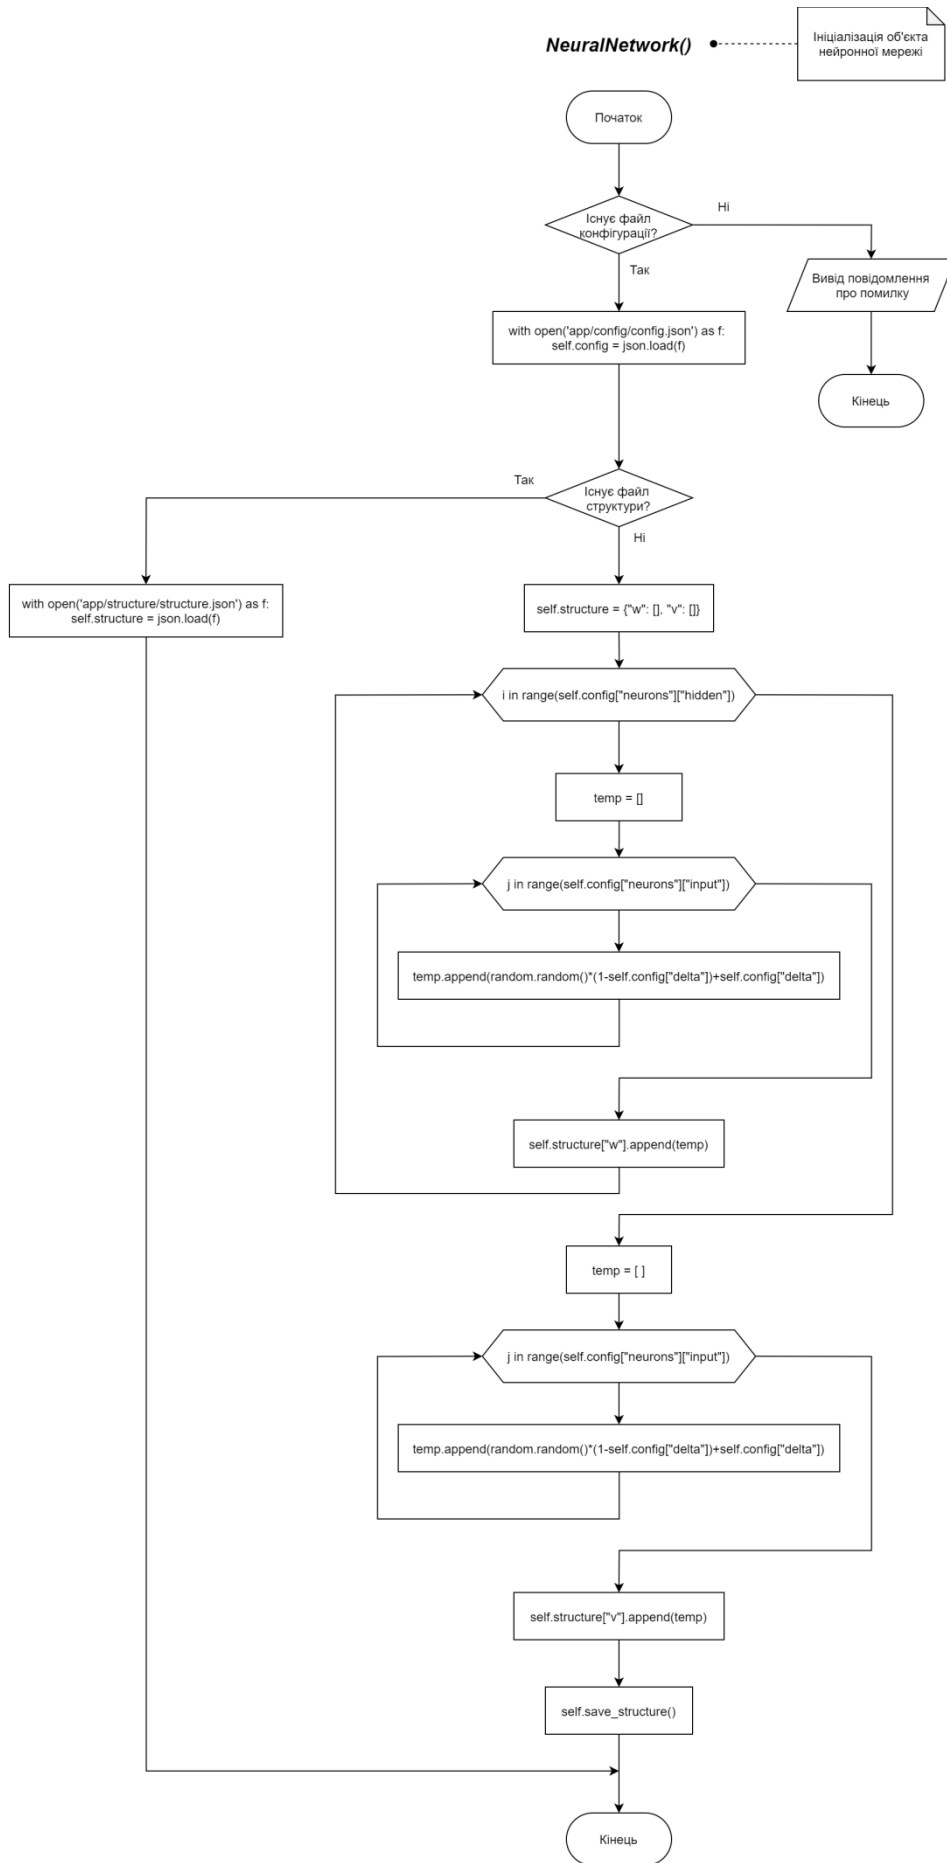


Рис. 4.1.3. Блок-схема ініціалізації нейронної мережі

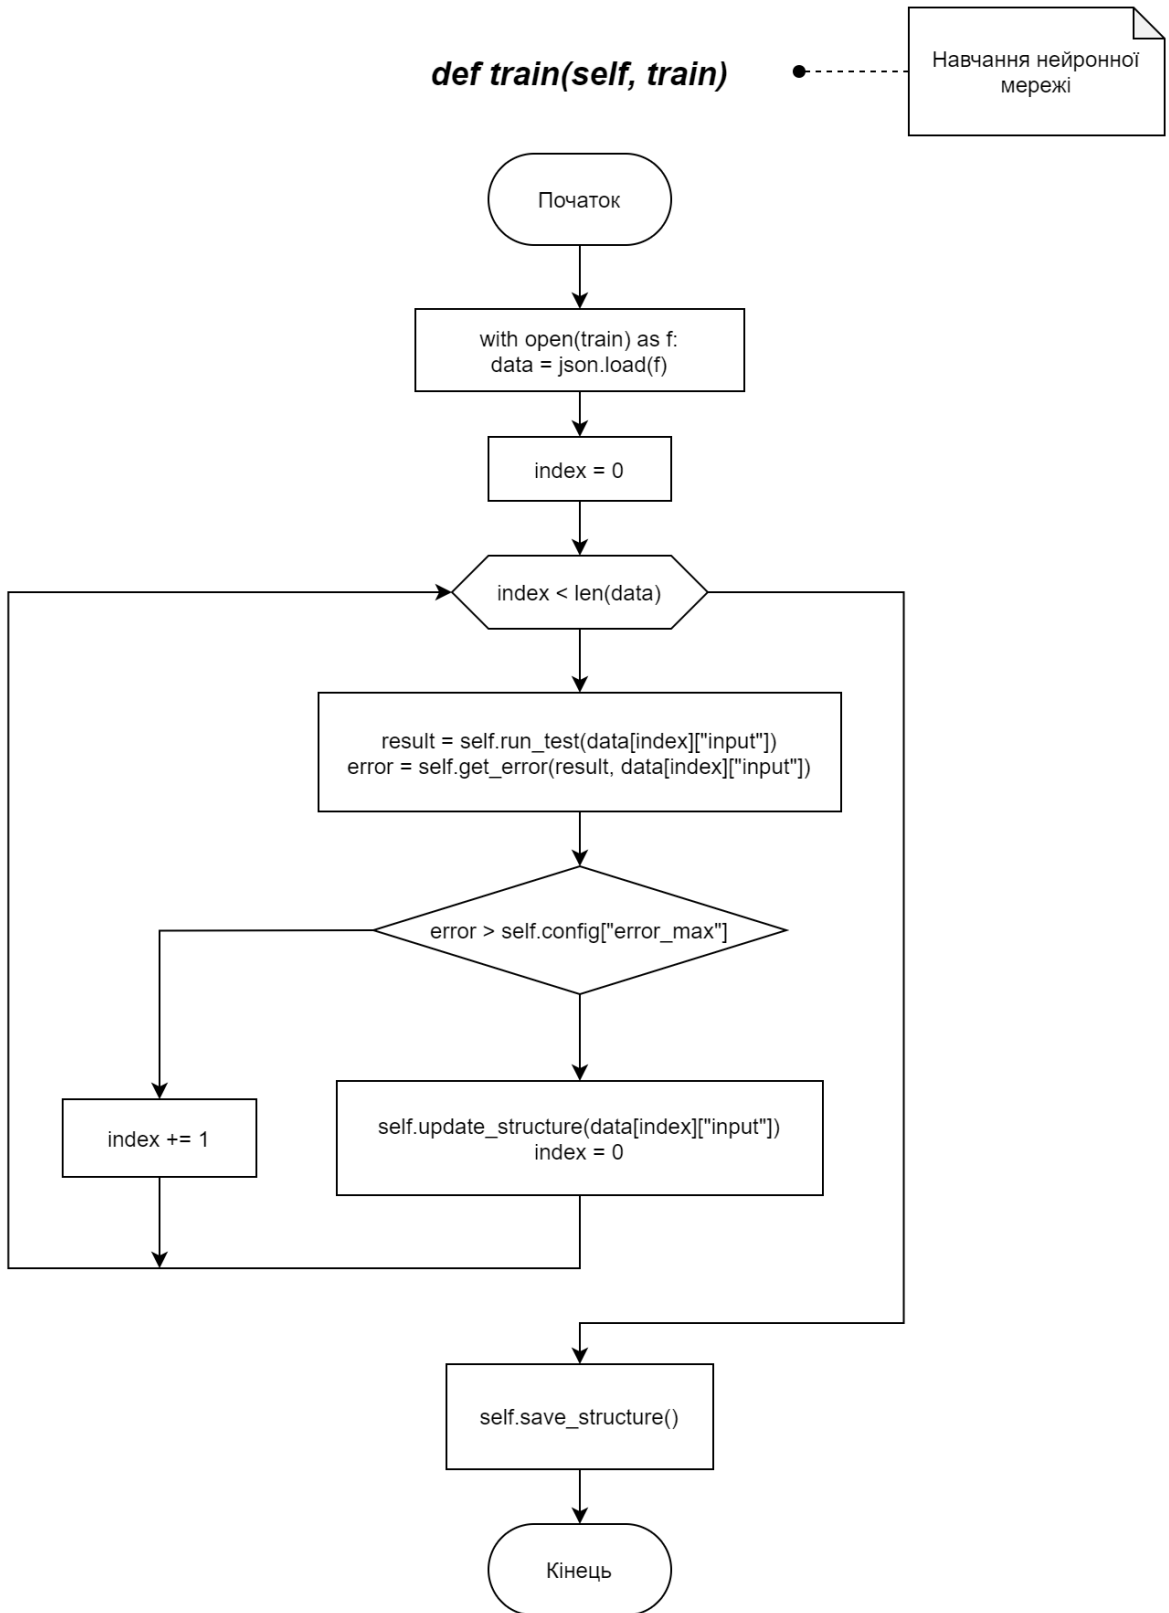


Рис. 4.1.4. Блок-схема навчання нейронної мережі

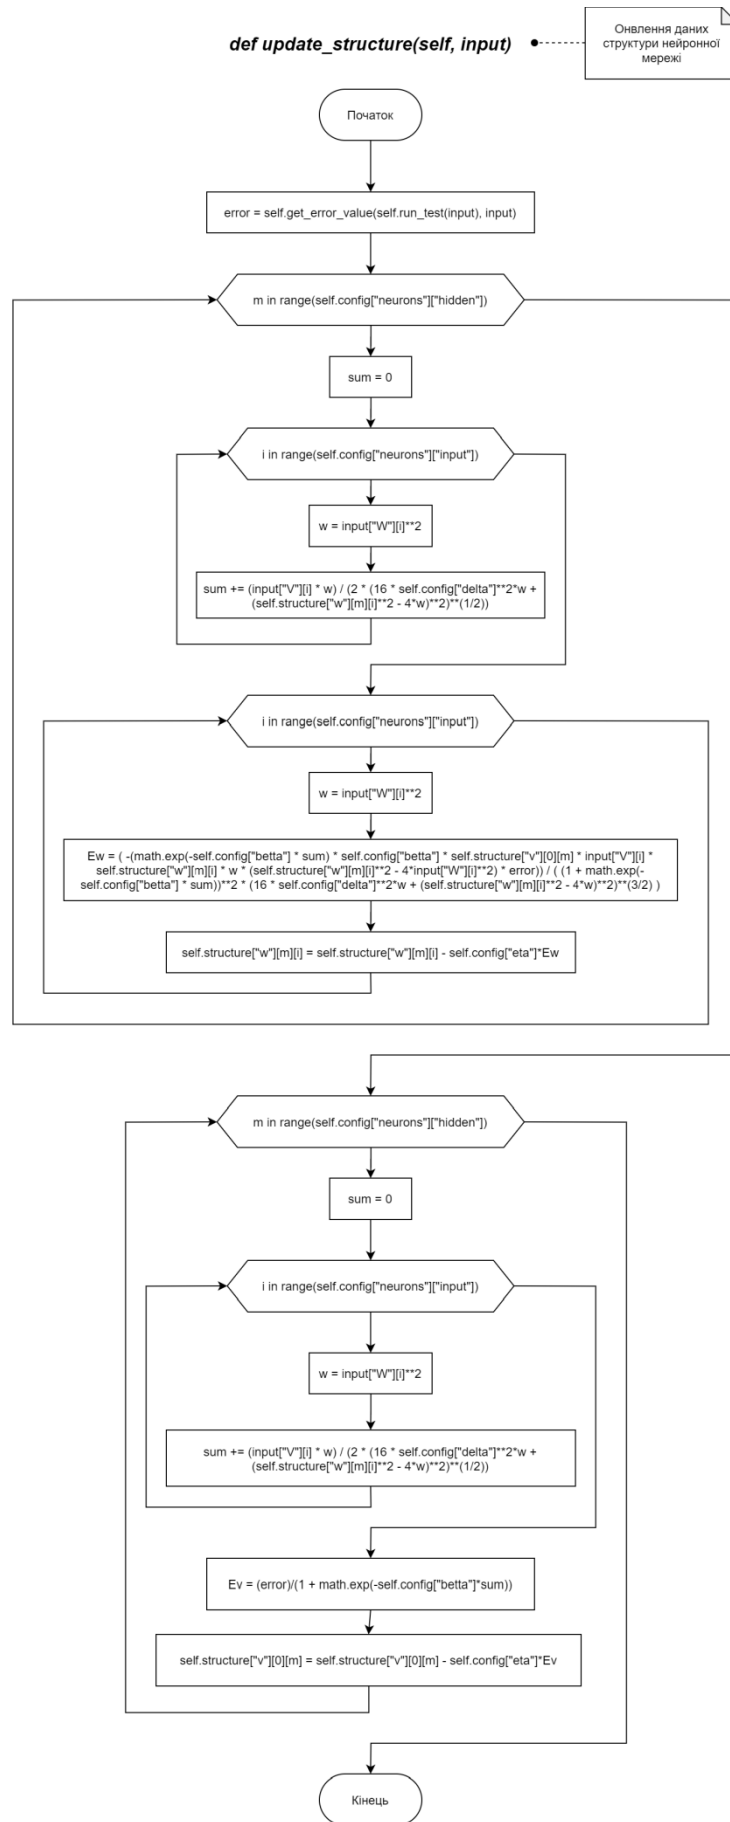


Рис. 4.1.5. Блок-схема оновлення даних структури нейронної мережі

На *Рис. 4.1.6.* показано файл `app.py` (повний код нейронної мережі представлено у Додатку В), який відповідає за створення, тренування та збереження моделі нейронної мережі.



```

import sys
import math
import os.path
import json
import random
import time

class NeuralNetwork:
    def __init__(self):
        try:
            with open('app/config/config.json') as f:
                self.config = json.load(f)
        except:
            print("Error: Configuration file is not found. (app/config/config.json)")
            exit()

        try:
            with open('app/structure/structure.json') as f:
                self.structure = json.load(f)
        except:
            self.structure = {"w": [], "v": []}
            for i in range(self.config["neurons"]["hidden"]):
                temp = []
                for j in range(self.config["neurons"]["input"]):
                    temp.append(random.random()*(1-self.config["delta"])+self.config["delta"])
                self.structure["w"].append(temp)

```

*Рис. 4.1.6. Файл нейромережі*

У файлі `config.json` (*Рис. 4.1.7*) міститься конфігурація нейронної мережі, за допомогою якого можна змінювати такі параметри як: кількість нейронів у сенсорному шарі, кількість нейронів у прихованому шарі, коефіцієнт затухання нейронів, крутизна функції активації, максимально допустима похибка при навчанні нейронної мережі, коефіцієнт швидкості навчання, коефіцієнт критерію резонансу.

```

1  {
2  "neurons": {
3      "input": 5,
4      "hidden": 10
5  },
6  "beta": 0.5,
7  "delta": 0.1,
8  "eta": 0.2,
9  "threshold": 1.5,
10 "error_max": 0.2,
11 "eps": 0.2
12 }

```

Рис. 4.1.7. Файл конфігурації нейромережі

```

1  [
2  {
3      "input": {
4          "v": [
5              0.004931038296757118,
6              0.2590306817667991,
7              0.3626365305737377,
8              0.33702154963992953,
9              0.3441765266494315
10             ],
11             "w": [
12                 0.1420166598678943,
13                 0.39808295856285153,
14                 0.463791038264512,
15                 0.48608857798837485,
16                 0.2598442303089756
17             ]
18         },
19         "output": [
20             1
21         ]
22     },

```

Рис. 4.1.8. Файл навчальної вибірки для нейронної мережі

```

1  [
2  {
3    "input":{
4      "v":[
5        0.12106533795459978,
6        0.1110741303685317,
7        0.2383120715969509,
8        0.06965053307910901,
9        0.008558299384211876
10     ],
11     "w":[
12       0.35843760727587287,
13       0.29113419456949113,
14       0.2985081286613175,
15       0.4537181587657341,
16       0.4232333077169691
17     ]
18   },
19   "output":[
20     0
21   ]
22 },
23 {
24   "input":{
25     "v":[
26       0.204850721789608,
27       0.26332445778822905,
28       0.2209178510877992,
29       0.4205433191847855,
30       0.4856431297564312
31     ],
32     "w":[
33       0.047834773844024736,
34       0.19633473720192196,
35       0.3431006430575602,
36       0.15735666443592938,
37       0.11095191562344436
38     ]
39   },
40   "output":[
41     0

```

Рис. 4.1.9. Файл тестової вибірки для нейронної мережі

На Рис. 4.1.8 та Рис. 4.1.9 показано файли train.json та test.json, що містять дані навчальної та тестової вибірки нейронної мережі відповідно.

```

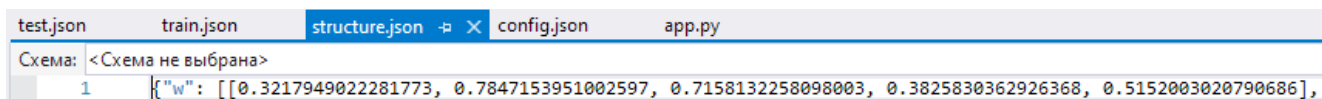
Test #1 error: 0.2377121803329233
Test #8 error: 0.20874199266665736
Test #1 error: 0.24343363253348124
Test #8 error: 0.20179621646313797
Test #1 error: 0.24104261244444566
Test #7 error: 0.20272005423788714
Test #1 error: 0.2347436674739768
Test #8 error: 0.20514804934720618
Test #1 error: 0.239635451421542
Test #9 error: 0.23632047585755367
Test #1 error: 0.26160071533871304
Test #9 error: 0.20817462688818464
Test #1 error: 0.2524738781303868
Test #8 error: 0.2021704021012696
Test #1 error: 0.24407926351542258
Test #8 error: 0.20278077546831252
Test #1 error: 0.24121715115001452
Test #8 error: 0.20114522779201688
Test #1 error: 0.2389814008031598
- Training is finished.

D:\Neural Network App 2\Neural Network App>_

```

*Рис. 4.1.10. Навчання нейронної мережі*

З *Рис. 4.1.10* видно, що нейронна мережа успішно закінчила навчання. Вагові коефіцієнти синаптичних зв'язків зберігаються у файлі `structure.json` (*Рис. 4.1.11*), для того, щоб у подальшому використанні програми не навчати нейронну мережу, а застосовувати уже навчену.



```

test.json  train.json  structure.json  config.json  app.py
Схема: <Схема не выбрана>
1 [{"w": [[0.3217949022281773, 0.7847153951002597, 0.7158132258098003, 0.3825830362926368, 0.5152003020790686],

```

*Рис. 4.1.11. Файл з вагами нейромережі після навчання*

```

C:\Windows\system32\cmd.exe
Microsoft Windows [Version 10.0.19042.1052]
(c) Корпорация Майкрософт (Microsoft Corporation). Все права защ
D:\Neural Network App\Neural Network App>python app.py test -vie
Test #1 [1]: 1 (1.41488392850893)
Test #2 [1]: 1 (1.4298772834823925)
Test #3 [1]: 1 (1.4045430243987058)
Test #4 [1]: 1 (1.3947588050263127)
Test #5 [1]: 1 (1.420177053997309)
Test #6 [0]: 0 (1.565256028444676)
Test #7 [1]: 0 (1.5295492536043973)
Test #8 [0]: 0 (1.5556274080657955)
Test #9 [0]: 0 (1.5660019773241762)
Test #10 [0]: 0 (1.5492587083160085)
D:\Neural Network App\Neural Network App>

```

*Рис. 4.1.12. Тестування осциляторної нейронної мережі*

На *Рис. 4.1.12* продемонстровано тестування нейронної мережі. 1 означає, що у даному тестовому прикладі був розпізнаний певний об'єкт внаслідок інформаційного резонансу, а 0 означає, що резонансних ефектів не виявлено. У квадратних дужках вказано правильну відповідь – розпізнано об'єкт чи ні, а після двокрапки вказано відповідь нейронної мережі. Аналіз тестування нейронної мережі показав, що вона ефективно працює, оскільки точність її розпізнавання складає 90%.

Аналогічний експеримент був проведений середовищі «Matlab».

Для навчання нейронної мережі вибрано 20 пар входів-виходів (елементів), з них 13 елементів з резонансом та 7 елементів без резонансу, які були успішно запам'ятовані. При валідації вибрано 5 елементи з них 2 елементи з резонансом та 3 без резонансу, які були успішно розпізнані. Як тестувальні приклади було вибрано 5 елементів без резонансу, і всі вони були успішно розпізнані (*Рис. 4.1.13*).





Рис. 4.1.13. Результат тестування роботи осциляторної нейронної мережі

Зокрема проведено ще одне тестування з іншими 20 елементами, всі вони були успішно розпізнані (Рис. 4.1.14).




Рис. 4.1.14. Результат другого тестування з іншими прикладами

Аналіз результатів показав, що точність розпізнавання осциляторною нейронною мережею, що реалізована у середовищі «Matlab», складає 100%.

#### 4.2. Чисельний розрахунок параметра складності навчання тришарової нейронної мережі та її оптимального розміру

На основі розробленої нелінійної математичної моделі оптимізації розміру багатшарової нейронної мережі [116] (Розділ 2, параграф 2.3) з умови мінімуму узагальненої похибки проведено в середовищі «Wolfram Mathematica» чисельний розрахунок залежності оптимальної кількості синаптичних зв'язків від числа навчальних прикладів ( $N_{\lambda_{ij}}^{opt} = f(N_p)$ ) для чотирьох значень вхідних образів  $N_{in} : 4; 10; 20; 50$  (Рис. 4.2.1). В подальшому **1** –  $N_{in} = 4$ ; **2** –  $N_{in} = 10$ ; **3** –  $N_{in} = 20$ ; **4** –  $N_{in} = 50$ , штрихові лінії – лінійне наближення. Як видно з Рис. 4.2.1,

функціональна залежність  $N_{\lambda_{ij}}^{opt} = f(N_p)$  на проміжку  $0 \leq N_p \leq 500$  має монотонно зростаючий характер. При збільшенні числа вхідних образів  $N_{in}$  зростає різниця між функціональною залежністю  $N_{\lambda_{ij}}^{opt} = f(N_p)$  в лінійній та нелінійній моделях узагальненої похибки. Зокрема, при  $N_p = 500$  і  $N_{in} = 50$  у нелінійній моделі оптимальне число синаптичних зв'язків є меншим на 20% порівняно з лінійною моделлю. Найменша різниця оптимального числа синаптичних зв'язків є при  $N_{in} = 4$ .




Рис. 4.2.1. Залежність оптимальної кількості синаптичних зв'язків від числа навчальних прикладів

На Рис. 4.2.2 зображено результати чисельних розрахунків узагальненої похибки в залежності від загальної кількості синаптичних зв'язків, тобто  $\varepsilon = \varphi(N_{\lambda_{ij}})$  при кількості навчальних прикладів  $N_p = 1000$  і  $N_{in} : 4; 10; 20; 50$ . Як видно з результатів чисельних розрахунків такі функціональні залежності

$\varepsilon = \varphi(N_{\lambda_{ij}})$  мають немонотонний характер. Мінімуму узагальненої похибки відповідає оптимальне число зв'язків  $N_{\lambda_{ij}}^{opt}$ , тобто  $\varepsilon_{\min} = \varphi(N_{\lambda_{ij}}^{opt})$ . З ростом числа вхідних образів  $N_{in}$  мінімум узагальненої похибки зсувається в сторону більшої кількості синаптичних зв'язків. При значеннях числа синаптичних зв'язків у інтервалі  $0 < N_{\lambda_{ij}} < 100$  значення узагальненої похибки у нелінійній моделі практично співпадає зі значенням у лінійній. При  $N_{\lambda_{ij}} \geq 100$  відбувається збільшення узагальненої похибки  $\varepsilon = \varphi(N_{\lambda_{ij}})$ . При чому в межах нелінійної моделі швидкість зростання узагальненої похибки  $\frac{\Delta\varepsilon}{\Delta N_{\lambda_{ij}}}$  є більшою порівняно із швидкістю зростання в лінійній.

Порівняння чисельних розрахунків узагальненої похибки в межах нелінійної моделі з комп'ютерним експериментом, який був проведений на прикладі обробки сигналів розподіленою волоконно-оптичною мережею для розпізнавання динамічних образів з використанням нейронних мереж [153, 154], показало кореляцію між похибкою отриманою в комп'ютерному експерименті і отриманими чисельними результатами при зростанні числа навчальних прикладів.




Рис. 4.2.2. Залежність узагальненої похибки від загальної кількості синаптичних зв'язків

На Рис. 4.2.3 зображено графічну залежність параметра складності навчання (кількість операцій виконаних нейронною мережею)  $C = N_p \times (N_{\lambda_{ij}}^{opt})^2$  від кількості навчальних прикладів  $N_p$ , тобто  $C = \phi(N_p)$ . Із збільшенням числа вхідних образів  $N_{in}$  та числа навчальних прикладів  $N_p$  ступінь складності навчання  $C$  зростає нелінійно. У лінійній моделі узагальненої похибки із збільшенням  $N_p$  ступінь складності навчання є вищою відносно нелінійної.




Рис. 4.2.3. Залежність параметра складності навчання від кількості навчальних прикладів

Із означення параметра складності навчання нейронної мережі  $C = N_p \times (N_{\lambda_{ij}}^{opt})^2$  випливає наступний практичний висновок: нейроемуляторам з продуктивністю сучасних персональних комп'ютерів ( $P = 10^9$  операцій в секунду) з кількістю навчальних прикладів  $N_p$  і розмірністю входів  $N_{in}$ , час навчання

нейронної мережі буде визначатись наступним співвідношенням  $\tau = \frac{N_p \times (N_{\lambda_{ij}}^{opt})^2}{P}$ .

Зокрема, при  $N_p = 500$ ,  $N_{in} = 50$ ,  $N_{\lambda_{ij}}^{opt} = 125$  час навчання нейронної мережі буде дорівнювати  $\tau = 7,8 \cdot 10^{-3}$  с.

## Висновки до розділу 4

1. Розроблено алгоритм навчання осциляторної нейронної мережі, яка програмно реалізована на мові Python для розпізнавання мультиспектральних образів на основі інформаційного резонансу.

2. У межах нелінійної математичної моделі оптимізації розміру багатошарової нейронної мережі з умови мінімуму узагальненої похибки виведені вирази для обчислення оптимального розміру мережі (кількість синаптичних зв'язків та кількість нейронів у прихованих шарах).

3. У середовищі «Wolfram Mathematica» розраховані графічні залежності узагальненої похибки мережі від кількості синаптичних зв'язків між нейронами при різних значеннях вхідних образів і фіксованій кількості навчальних прикладів та графічні залежності оптимальної кількості синаптичних зв'язків від числа навчальних прикладів при різних значеннях вхідних образів.

4. Проведено оцінку часу навчання нейронної мережі на основі співвідношень для оптимального числа синаптичних зв'язків між нейронами та оптимального числа нейронів в прихованих шарах.

5. Встановлено, що з ростом числа вхідних образів  $N_{in}$  та числа навчальних прикладів  $N_p$  мінімум узагальненої похибки зсувається в сторону більшої кількості синаптичних зв'язків.

## ВИСНОВКИ

У дисертаційній роботі з використанням методів системного аналізу досліджено архітектуру і властивості нейронних мереж з лінійними та нелінійними осциляторними нейронами, стиск вхідних образів нейронною мережею методом діагоналізації матриці вагових синаптичних зв'язків, умови інформаційного резонансу в тришаровій осциляторній нейронній мережі в межах евклідової метрики, трансформацію вхідних образів осциляторною нейронною мережею з топологією «ланцюжка» та «кільця» нелінійних осциляторних нейронів, умови мінімуму узагальненої похибки, яка містить у собі похибку апроксимації даних нейронною мережею в нелінійному наближенні та похибку опису моделі.

В ході дисертаційного дослідження *розроблено* нові методи:

- метод стиску вхідних образів на основі діагоналізації матриці вагових синаптичних зв'язків;
- метод розпізнавання мультиспектральних образів осциляторною нейронною мережею на основі інформаційного резонансу;
- метод шифрування інформації ланцюговою та кільцевою нейромережами з нелінійними осциляторними нейронами;
- спосіб шифрування інформації на основі синтезу діагоналізованої нейронної мережі та алгоритму AES з постійно змінним асиметричним ключем для кожного вхідного образу;
- спосіб зменшення числа операцій агрегації на основі модифікованої теореми Хехт-Нільсена для нейронної мережі з діагональними синаптичними зв'язками;
- нелінійну модель оптимізації структури багатошарової нейронної мережі на основі мінімізації нелінійної узагальненої похибки, що базується на принципі мінімальної довжини опису.



На основі методології системного аналізу було розв'язано сформульовані задачі дисертаційного дослідження та отримано нові наукові результати, на підставі яких можна зробити такі висновки:

1. Встановлено, що діагоналізація матриці синаптичних зв'язків між нейронами приводить до формування головних компонент вагових коефіцієнтів синаптичних зв'язків, які враховують взаємодію між усіма нейронами, та, відповідно, до зменшення часу навчання нейронної мережі.

2. Встановлено, що на основі модифікованої теореми Хехт-Нільсена для тришарової діагоналізованої нейромережі можна апроксимувати функцію від  $n$  змінних з заданою точністю  $\varepsilon > 0$  за допомогою однієї операції агрегування.

3. Показано, що діагоналізована нейрокриптосистема AES з постійно змінним асиметричним ключем для кожного вхідного образу має ступінь криптостійкості вищий, ніж синтезована недіагоналізована нейромережа з алгоритмом AES.

4. Розроблено математичну модель архітектури лінійної та нелінійної осциляторних нейронних мереж, яка враховує: власну динаміку нелінійного нейрона, що виконує функції інтегратора-резонатора; умови резонансу та генерації коливань нелінійним нейроном залежно від співвідношення загального числа імпульсів сигналу до порогового значення, які подаються на вхід нейронів; час релаксації нейрона після потенціалу його дії.

5. Встановлено, що система взаємопов'язаних нелінійних осциляторних нейронів з топологією «ланцюжка» та «кільця» має вищий ступінь стохастичності морфології сигналу на виході нейромережі порівняно з сигналом на виході окремого нелінійного осциляторного нейрона, що підвищує ступінь криптостійкості нейросистеми.

6. Сформульовано критерій розпізнавання мультиспектральних сигналів (з амплітудою співмірною рівню шуму) при резонансі, який визначає, що евклідова відстань між частотою зовнішнього сигналу та власною частотою коливань осциляторних нейронів повинна бути меншою, ніж ширина частотного спектру шумового сигналу.

7. Розроблено алгоритм навчання осциляторної нейронної мережі, яка програмно реалізована на мові Python для розпізнавання мультиспектральних образів на основі інформаційного резонансу.

8. Побудовано нелінійну математичну модель оптимізації кількості синаптичних зв'язків та нейронів у прихованому шарі нейронної мережі. З умови мінімуму нелінійної узагальненої похибки встановлено, що з ростом числа вхідних образів  $N_{in}$  та числа навчальних прикладів  $N_p$  мінімум узагальненої похибки зсувається в сторону більшої кількості синаптичних зв'язків.

## СПИСОК ВИКОРИСТАНОЇ ЛІТЕРАТУРИ

1. Бехтерева Н. П. Здоровый и больной мозг человека. М.: АСТ; СПб.: Сова, 2010. 399 с. URL: <https://www.twirpx.com/file/2583922/>
2. Xin Biao Lu, Bu Zhi Qin. Synchronization in Complex Networks. Nova Science Pub Inc. 2011. 146 p. URL: <https://ua1lib.org/book/1243384/200231?id=1243384&secret=200231>
3. Nikonov D.E., Csaba G., Porod W., Shibata T.; Voils D., Hammerstrom D., Young I.A., Bourianoff G.I. Coupled-Oscillator Associative Memory Array Operation for Pattern Recognition. *Electrical and Computer Engineering Faculty Publications and Presentations*. 2015. Vol. 348, No1. P. 85–93. URL: <https://core.ac.uk/download/pdf/37771867.pdf>
4. Chen Ke. On the Dynamic Pattern Analysis, Discovery and Recognition. *IEEE Systems, Man & Cybernetics Society E-Newsletter*. 2005. Vol. 12. P. 1–10 URL: <http://www.cs.man.ac.uk/~kechen/publication/dynamic-pattern.pdf>
5. Siddeeq Y. Ameen, Ali H. Mahdi. AES Cryptosystem Development Using Neural Networks. *International Journal of Computer and Electrical Engineering*. 2011. Vol. 3. No 2. P. 309–314. URL: <http://www.ijcee.org/show-37-629-1.html>
6. Хайкин С. Нейронные сети: полный курс, 2-е изд.: Пер. с англ. М.: ООО «И.Д. Вильямс». 2016. 1104 с. URL: <http://i.uran.ru/webcab/system/files/bookspdf/neyronnye-seti-polnyy-kurs/229022.pdf>
7. Bodyanskiy Y., Deineko A., Pliss I., Chala O., Nortsova A.. Matrix Fuzzy-Probabilistic Neural Network in Image Recognition Task. *2020 IEEE Third International Conference on Data Stream Mining & Processing (DSMP)*. 2020. P. 33–36. URL: <https://ieeexplore.ieee.org/abstract/document/9204236>
8. Nikonov D. E.; Csaba G., Porod W., Shibata T., Voils D.; Hammerstrom D., Young I. A., Bourianoff G. I. Coupled-Oscillator Associative Memory Array Operation for Pattern Recognition. *Electrical and Computer Engineering Faculty*

- Publications and Presentations*. 2015. Vol. 348. No 1. P. 85–93. URL: [http://pdxscholar.library.pdx.edu/ece\\_fac/348](http://pdxscholar.library.pdx.edu/ece_fac/348)
9. Борисюк Н.Г., Борисюк Р.М., Казанович Я.Б., Лузянина Т.Б., Турова Т.С., Цымбалюк Г.С. Осциляторные нейронные сети. Математические результаты и приложения, *Матем. Моделирование*, 1992, Т. 4, № 1. С. 3–43. URL: <http://www.mathnet.ru/links/5db437f15df5f0bbcabfa01ca6057320/mm2033.pdf>
  10. Крюков В.И., Борисюк Г.Н., Кириллов А.Б., Коваленко Е. И. Метастабильные и неустойчивые состояния в мозге. Пушино ОНТИ НЦБИ АН СССР 1986. 114 с. URL: [https://www.alib.ru/au-kryukov/nm-metastabilnmmnye\\_neustojchivye\\_sostoyaniya\\_mozge/](https://www.alib.ru/au-kryukov/nm-metastabilnmmnye_neustojchivye_sostoyaniya_mozge/)
  11. Bower J., Wilson M.. A Computer Simulation of Olfactory Cortex with Functional Implications for Storage and Retrieval of Olfactory Information. *Neural Information Processing Systems*. 1987. P. 114–126. URL: <https://proceedings.neurips.cc/paper/1987/file/e369853df766fa44e1ed0ff613f563bd-Paper.pdf>
  12. George S. T., Subathra M. S. P., Sairamya N. J., Susmitha L., Joel Premkumar M. Classification of epileptic EEG signals using PSO based artificial neural network and tunable-Q wavelet transform. *Biocybernetics and Biomedical Engineering*. 2020. Vol. 40. P. 709–728. URL: <http://yadda.icm.edu.pl/yadda/element/bwmeta1.element.baztech-47489b7f-299b-4f8e-9e1b-03b4f4f300d6>
  13. Wilson H. R., Cowan J. D. A mathematical theory of the functional dynamics of cortical and thalamic nervous tissue. *Kybernetik*. 1973. Vol. 13. P. 55–80. URL: <https://link.springer.com/article/10.1007/BF00288786>
  14. Ermentrout G., Kopell N. Frequency Plateaus in a Chain of Weakly Coupled Oscillators, I. *Mathematics. Siam Journal on Mathematical Analysis*. 1984. Vol. 15. No 2. P. 215–237. URL: <https://epubs.siam.org/doi/10.1137/0515019>
  15. Никитин К. В. Применение импульсных рекуррентных нейронных сетей для решения задачи распознавания динамических образов: дис. ... канд. тех.

- наук: 05.13.01. Санкт-Петербург, 2013. 245 с. URL: <http://tekhnosfera.com/primenenie-impulsnyh-rekurrentnyh-neyronnyh-setey-dlya-resheniya-zadachi-raspoznavaniya-dinamicheskikh-obrazov#ixzz6xwhZqjyw>
16. Тимошук П. В. Порівняльний аналіз моделей нейронних осциляторів. *Видавництво Львівської політехніки*. 2009. С. 243–249. URL: <http://vlp.com.ua/files/38.pdf>
17. Murrey A. E., Swith A. V. W. Asynchronous VLSI neural networks using pulse-stream arithmetic. *IEEE Journal of Solid-State Circuits*. 1988. Vol. 23. No 3. P. 688–697. URL: <https://ieeexplore.ieee.org/document/307>
18. Gerstner W., Kistler W. M. Spiking Neuron Models. *Cambridge University Press*. 2002. P. 1–28. URL: <https://www.cambridge.org/core/books/spiking-neuron-models/introduction/D7964780AA99C55697BA9D7BE00ED7D3>
19. Smith G. D., Cox C. L., Sherman S. M., Rinzel J. Fourier Analysis of Sinusoidally Driven Thalamocortical Relay Neurons and a Minimal Integrate-and-Fire-or-Burst Model. *J. Neurophysiol.* 2000. Vol. 83, No 1. P. 588–610. URL: <https://journals.physiology.org/doi/full/10.1152/jn.2000.83.1.588>
20. Izhikevich E. M. Resonate-and-fire neurons. *Neural Networks*. 2001. Vol. 14. P. 883–894. URL: <https://www.izhikevich.org/publications/resfire.pdf>
21. Ermentrout G. B. Type I membranes, phase resetting curves, and synchrony. *Neural Comput.* 1996. Vol. 8(5), P. 979–1001. URL: <https://pubmed.ncbi.nlm.nih.gov/8697231/>
22. Ermentrout G. B., Kopell N. Parabolic bursting in an excitable system coupled with a slow oscillation. *SIAM Journal on Applied Mathematics*. 1986. Vol. 46, No 2. P. 233–253. URL: <https://www.jstor.org/stable/2101582>
23. Hoppensteadt F. C., Izhikevich E. M. Weakly Connected Neural Networks. *Applied Mathematical Sciences*. New York: Springer-Verlag, 1997. 403 p. URL: <https://www.springer.com/gp/book/9780387949482>
24. Izhikevich E. M. Simple model of spiking neurons. *IEEE Trans. Neural Networks*. 2003. Vol. 14. No 6. P. 1569–1572. URL: <https://www.izhikevich.org/publications/spikes.pdf>

25. Lucas D.R., Oliveira, Rogerio M. Gomes, Bruno A. Santos, Henrique E. Borges. Effects of the parameters on the oscillation frequency of Izhikevich spiking neural networks. *Neurocomputing*. 2019. Vol. 337. P. 251–261. URL: <https://www.sciencedirect.com/journal/neurocomputing/vol/337/suppl/C>
26. Fitz-Hugh R. Impulses and physiological states in theoretical models of nerve membranes. *Biophys. J.* 1961. Vol. 1. P. 445–446. URL: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC1366333/>
27. Rose R. M., Hindmarsh J. L. The assembly of ionic currents in a thalamic neuron. The three-dimensional model. *Proc R Soc Lond B Biol Sci.* 1989. Vol. 237. P. 267–288. URL: <https://pubmed.ncbi.nlm.nih.gov/2571154/>
28. Morris C., Lecar H. Voltage oscillations in the barnacle giant muscle fiber. *Biophys. J.* 1981. Vol. 35. P. 193–213. URL: <https://pubmed.ncbi.nlm.nih.gov/7260316/>
29. Hodgkin A. L., Huxley A. F. A quantitative description of membrane current and application to conduction and excitation in nerve. *J. Physiol.* 1954. Vol. 117. P. 500–544. URL: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC1392413/>
30. Wilson H. R. Simplified dynamics of human and mammalian neocortical neurons. *J. Theor. Biol.* 1999. Vol. 200, No 4. P. 375–388. URL: <https://www.sciencedirect.com/science/article/abs/pii/S0022519399910020>
31. Kuramoto, Y., Chemical Oscillations, Waves, and Turbulence. *Berlin-Heidelberg-New York-Tokyo, Springer-Verlag*. 1984. 156 p. URL: <https://onlinelibrary.wiley.com/doi/abs/10.1002/zamm.19860660706>
32. Новиков А. В. Нелинейная динамика осцилляторных нейронных сетей в задачах кластерного анализа: дис. ... канд. тех. наук: 05.13.01. Санкт-Петербург, 2017. 105 с. URL: <http://www.dslib.net/sys-analiz/nelinejnaja-dinamika-oscilljatornyh-nejronnyh-setej-v-zadachah-klasternogo-analiza.html>
33. Belyaev M. A., Velichko A. A. Capacitorless model of a VO<sub>2</sub> oscillator. *IOP Conf. Ser.: Mater. Sci. Eng.* 2020. Vol. 734. P. 012151. URL: <https://iopscience.iop.org/article/10.1088/1757-899X/734/1/012151/meta>

34. Velichko A. A., Belyaev M. A. An Investigation of the Effect of the Thermal Coupling Time Delay on the Synchronization of VO<sub>2</sub>-Oscillators. *Technical Physics Letters*. 2019. Vol. 45, No 2. P. 61–64. URL: <http://velichko.site/en/author/admin/>
35. Яншин В.В. Анализ и обработка изображений: принципы и алгоритмы. М.: Машиностроение, 1994. 112 с. URL: <https://ua1lib.org/book/1154579/e539b8?id=1154579&secret=e539b8>
36. Анисимов Б. В., Курганов В. Д., Злобин В. К. Распознавание и цифровая обработка изображений. М.: Высшая школа, 1983. 149 с. URL: <http://padabum.com/d.php?id=32852>
37. Дж. Ту, Р. Гонсалес. Принципы распознавания образов. Пер. с англ. Гуревича И.Б. М.: Мир, 1978. 413 с. URL: <https://www.twirpx.com/file/2270393/>
38. Оппенгейм А., Шафер Р. Цифровая обработка сигналов: Пер. с англ. / Под ред. С. Я. Шаца. М.: Техносфера, 2006. 856 с. URL: <https://www.twirpx.com/file/20958/>
39. Осовский, С. Нейронные сети для обработки информации: Пер. с польск. И.Д. Рудинского. М.: Финансы и статистика, 2002. 344 с. URL: <https://www.twirpx.com/file/1854258/>
40. L. Rabiner, B. H. Juang. Fundamentals of speech recognition. Englewood Cliffs, NJ: Prentice-Hall, 1993. 507 p. URL: <https://lib.ugent.be/en/catalog/rug01:001033127>
41. Goldman M. J. Principles of Clinical Electrocardiography. Unknown Binding—Import: Lange Medical Publications, 1976. 412 p. URL: <https://www.amazon.com/Principles-clinical-electrocardiography-M-J-Goldman/dp/0870410865>
42. Viola P., Jones M.. Robust Real-time object detection. *International Journal of Computer Vision*. 2001. Vol. 57, No 2. P. 137–154. URL: <http://citeseerx.ist.psu.edu/viewdoc/summary?doi=10.1.1.110.4868>

- 43.Лещенко С. П. Радіолокаційне розпізнавання повітряних об'єктів по їх дальнісним портретам та залученням додаткових ознак. *Наука і техніка Повітряних Сил Збройних Сил України*. 2020. № 2. С. 83–92. URL: <https://journal-hnups.com.ua/index.php/nitps/article/view/225>
- 44.Лещенко С.П. Кореляційний алгоритм радіолокаційного розпізнавання повітряних об'єктів по їх дальнісним портретам з відмовами. *Системи обробки інформації*. 2020. № 4(163). С. 66–76. URL: <https://journal-hnups.com.ua/index.php/soi/article/view/478>
- 45.Тоцкий А. В., Молчанов П. А., Поспелов Б. Б. Распознавание летательных аппаратов по радиолокационным дальностным профилям *Авиационно-космическая техника и технология*. 2010. № 5. С. 77–82. URL: [http://nbuv.gov.ua/UJRN/aktit\\_2010\\_5\\_14](http://nbuv.gov.ua/UJRN/aktit_2010_5_14).
- 46.Лещенко С. П. Вплив помилок виміру швидкості та ракурсу повітряних об'єктів на якість їх розпізнавання при використанні радіолокаційних дальнісних портретів. *Системи озброєння і військова техніка*. 2019. № 4. С. 23–30. URL: <http://www.hups.mil.gov.ua/periodic-app/article/19626>
- 47.Smith C.R., Goggans P. M. Radar target identification. *IEEE Antennas and Propagation Magazine*. 1993. Vol. 35, No 2. P. 27–38. URL: <https://ieeexplore.ieee.org/abstract/document/207649>
- 48.Li H.-J., Yang S.-H. Using range profiles as feature vectors to identify aerospace objects. *IEEE Transactions on Antennas and Propagation*. 1993. Vol. 41. No 3. P. 261–268. URL: <https://ieeexplore.ieee.org/abstract/document/233138>
- 49.Zyweck A., Bogner R. Radar target classification of commercial aircraft *IEEE Transactions on Aerospace and Electronic Systems*. 1996. Vol. 32. P. 598–606. URL: <https://digital.library.adelaide.edu.au/dspace/handle/2440/2372>
- 50.Jacobs S. P., O'Sullivan J. A. Automatic target recognition using sequences of high resolution radar range-profiles. *IEEE Transactions on Aerospace and Electronic Systems*. 2000. Vol. 36. No 2. P. 364–381. URL: <https://ieeexplore.ieee.org/document/845214>



51. Dequan Zhou, Guosui Liu, Jianxin Wang. Spatio-temporal target identification method of high-range resolution radar. *Pattern Recognition*. 2000. Vol. 33, No 1. P. 1–7. URL: <https://www.sciencedirect.com/science/article/abs/pii/S0031320398000521>
52. Xian-Da Zhang, Yu Shi, Zheng Bao. A new feature vector using selected bispectra for signal classification with application in radar target recognition. *IEEE Transactions on Signal Processing*. 2001. Vol. 49, No 9. P. 1875–1885. URL: <https://ieeexplore.ieee.org/document/942617>
53. Dale E. Nelson, Janusz A. Starzyk, D. David. Ensley Iterated Wavelet Transformation and Signal Discrimination for HRR Radar Target Recognition. *IEEE Transactions on Systems Man and Cybernetics - Part A Systems and Humans*. 2003. Vol. 33. P. 52–57. URL: <https://ieeexplore.ieee.org/document/1206455>
54. Du L., Liu H., Xing M.. Radar HRRP target recognition based on higher order spectra. *Computer Science, Mathematics. IEEE Transactions on Signal Processing*. 2005. Vol. 53, No 7. P. 2359–2368. URL: <https://ieeexplore.ieee.org/document/1453769>
55. Tait P. Introduction to Radar Target Recognition (Radar, Sonar and Navigation). The Institution of Engineering and Technology, London. 2005. 397 p. URL: <https://www.amazon.com/Introduction-Radar-Target-Recognition-Electromagnetics/dp/0863415016>
56. Филимонов А. Б., Фам Фыонг Кыонг. Методы формирования информативных признаков радиолокационных дальностных портретов воздушных целей. *Мехатроника, автоматизация, управление*. 2016. Т. 17. С. 273–281. URL: <https://mech.novtex.ru/jour/article/view/292>
57. Фам Фыонг Кыонг. Нейросетевая схема распознавания воздушных целей по радиолокационным дальностным портретам *Международный научно-исследовательский журнал*. 2016. № 4. С. 204–210. URL: <https://research-journal.org/wp-content/uploads/2016/04/4-2-46.pdf>

58. Yakov D. Shirman. Computer simulation of aerial target radar scattering, recognition, detection, and tracking. Boston – London: Artech House, 2001. 307 p. URL: <https://us.artechhouse.com/Computer-Simulation-of-Aerial-Radar-Scattering-Recognition-Detection-P1824.aspx>
59. Рунион Р. Справочник по непараметрической статистике. Современный подход. Пер. с английского Е. З. Демиденко. Предисловие Ю. Н. Тюрина. Москва, Финансы и статистика, 1982. 198 с. URL: <https://www.twirpx.com/file/41138/>
60. Дьяконов В. П. Вейвлеты. От теории к практике. 2-е изд. М.: Солон-Р, 2010. 400 с. URL: <https://www.twirpx.com/file/2169886/>
61. Смоленцев Н. К. Основы теории вейвлетов. Вейвлеты в MATLAB. М.: ДМК Пресс, 2014. 628 с. URL: <http://pzs.dstu.dp.ua/DataMining/wave/bibl2014.pdf>
62. Wasserman P.D. Advanced methods in neural computing. *Computer Science*. 1993. P. 35–55. URL: <https://www.semanticscholar.org/paper/Advanced-methods-in-neural-computing-Wasserman/b6bbc9f8fc24aca958e70b041d5b76471f6fcd69>
63. S. Arivazhagan, T. G. Subash Kumar, L. Ganesan. Texture Classification Using Curvelet Transform. *International Journal Of Wavelets, Multiresolution And Information Processing* vol. 2007. Vol. 5, No 3. P. 451–464. URL: <https://www.worldscientific.com/worldscinet/ijwmip>
64. Kanchana M., Kanchana M., Varalakshmi P. Texture Classification Using Discrete Shearlet Transform. *International Journal of Scientific Research*. 2012. Vol. 2. P. 194–196. URL: [https://www.researchgate.net/publication/314384632\\_Texture\\_Classification\\_Using\\_Discrete\\_Shearlet\\_Transform](https://www.researchgate.net/publication/314384632_Texture_Classification_Using_Discrete_Shearlet_Transform)
65. Unser M. Texture classification and segmentation using wavelet frames. *IEEE Transactions on Image Processing*. 1995. Vol. 4, No 11. P. 1549–1560. URL: <https://ieeexplore.ieee.org/document/469936/authors#authors>

66. Shin Fujieda, Kohei Takayama, Toshiya Hachisuka. Wavelet Convolutional Neural Networks. *Computer Vision and Pattern Recognition*. 2018. P. 1–10. URL: <https://arxiv.org/abs/1805.08620>
67. Stephane G. Mallat. A theory for multiresolution signal decomposition: the wavelet representation *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 1989. P. 673–690. URL: <http://citeseerx.ist.psu.edu/viewdoc/summary?doi=10.1.1.64.6732>
68. Krizhevsky A., Sutskever I., G. Hinton. ImageNet Classification with Deep Convolutional Neural Networks. *Communications of the ACM*. Vol. 60. P. 84–90. URL: <https://dl.acm.org/doi/10.1145/3065386>
69. LeCun Y., Jackel L. D., Boser B., Denker J. S., Graf H. P., Guyon I., Henderson D., Howard R. E., Hubbard W. Handwritten Digit Recognition: Applications of Neural Net Chips and Automatic Learning. *IEEE Communication*. 1989. P. 41–46. URL: <http://yann.lecun.com/exdb/publis/pdf/lecun-89c.pdf>
70. Li W., Wu G., Zhang F., Du Q. Hyperspectral image classification using deep pixel-pair features. *IEEE Trans. Geosci. Remote Sens.* 2017. Vol. 55. No 2. P. 844–853. URL: <https://ieeexplore.ieee.org/document/7736139>
71. Bin Pan, Zhenwei Shi, Xia Xu. R-VCANet: A New Deep Learning-Based Hyperspectral Image Classification Method. *IEEE Journal Of Selected Topics In Applied Earth Observations And Remote Sensing*. 2017. Vol. 10. P. 1975–1986. URL: <https://levir.buaa.edu.cn/publications/RVACNet-R2.pdf>
72. Feng Liang, Zhichao Tian, Ming Dong, Shuting Cheng, Li Sun, Hai Li, Yiran Chen, Guohe Zhang. Efficient neural network using pointwise convolution kernels with linear phase constraint. *Neurocomputing*. 2021. Vol. 423. P. 572–579. URL: <https://www.sciencedirect.com/science/article/abs/pii/S0925231220316453>
73. Meilu Zhu, Daming Shi, Junbin Gao. Branched convolutional neural networks incorporated with Jacobian deep regression for facial landmark detection. *Neural Networks*. 2019. Vol. 118. P. 127–139. URL: <https://pubmed.ncbi.nlm.nih.gov/31254767/>

74. Wang-Q Lim. The discrete shearlet transform: a new directional transform and compactly supported shearlet frames. *IEEE Trans Image Process.* 2010. Vol. 19. P. 1166–1180. URL: <https://pubmed.ncbi.nlm.nih.gov/20106737/#affiliation-1>
75. Ya-Li Hou, Yao-yao Song, X. Hao, Yan Shen, Manyi Qian. Multispectral pedestrian detection based on deep convolutional neural networks. *Infrared Physics and Technology.* 2018. Vol. 94. P. 69–77. URL: <https://www.sciencedirect.com/science/article/abs/pii/S1350449517308708>
76. Eun-Jin Choi, Dong-Jo Park. Human detection using image fusion of thermal and visible image with new joint bilateral filter. *5th International Conference on Computer Sciences and Convergence Information Technology*, 2010. P. 882–885. URL: <https://ieeexplore.ieee.org/document/5711182>
77. Verma B., Blumenstein M., Kulkarni S. A new compression technique using an artificial neural network. *Faculty of Information and Communication Technology, Griffith University. Australia*, 2004. P. 172–178. URL: <https://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.50.2305&rep=rep1&type=pdf>
78. Hinton G. E., Salakhutdinov R. R. Reducing the Dimensionality of Data with Neural Networks. *Science.* 2006. Vol. 313, No 5786. P. 504–507. URL: <https://science.sciencemag.org/content/313/5786/504.abstract>
79. Ле Мань Ха. Свёрточная нейронная сеть для решения задачи классификации. *Труды МФТИ.* 2016. Том 8, № 3. С. 91–97. URL: [https://mipt.ru/upload/medialibrary/659/91\\_97.pdf](https://mipt.ru/upload/medialibrary/659/91_97.pdf)
80. Поліщук У., Ткаченко О., Цимбал Ю. Ущільнення зображень за допомогою нейроподібних структур моделі геометричних перетворень. Видавництво Національного університету «Львівська політехніка», 2010. № 663. С. 275–280. URL: <http://ena.lp.edu.ua/bitstream/ntb/7980/1/44.pdf>
81. Поліщук У. В. Ущільнення зображень з регулюванням втрат на основі нейроподібних структур геометричних перетворень. *Наукові праці. Вісник Національного університету «Львівська політехніка»: Комп'ютерні*

- системи та інформаційні технології*. 2010. № 672. С. 316–322. URL: <http://ena.lp.edu.ua:8080/xmlui/handle/ntb/7462>
82. Gaetan Kerschen, Jean-Claude Golinval. Feature extraction using auto-associative neural networks. *Smart Materials and Structures*, 2004. Vol. 13, No 1. P. 211–219. URL: <https://iopscience.iop.org/issue/0964-1726/13/1>
83. Nandakishore Kambhatla, Todd K. Leen. Dimension Reduction by Local Principal Component Analysis. *Neural Computation*, 1997. Vol. 9. P. 1493–1516. URL: <https://direct.mit.edu/neco/article/9/7/1493/6105/Dimension-Reduction-by-Local-Principal-Component>
84. Гриценко В.И., Шлезингер М.И. Взаимосвязь проблем распознавания образов, машинного мышления и обучения. *Международный научно-технический журнал «Проблемы управления и информатики»*. 2020. № 3. С. 108–136. URL: [http://www.irtc.org.ua/image/publications/sch2020\\_bandwagon](http://www.irtc.org.ua/image/publications/sch2020_bandwagon)
85. Степанова А. Ю., Клименко С. В., Слипченко О. О., Михайлов Н. С. Исследование криптостойкости систем на основе нейронных сетей. *Актуальні проблеми автоматизації та інформаційних технологій*. 2017. Т.21. С. 152–161. URL: <https://actualproblems.dp.ua/index.php/APAIT/article/view/118>
86. Нейронная сеть Google изобрела собственный протокол шифрования. URL: <https://habr.com/post/398645/> (дата звернення: 18.06.2021)
87. Назаркевич М. А., Возний Я. В., Назаркевич Г. Я. Розроблення методу машинного навчання при біометричному захисті із новими методами фільтрації. *Кібербезпека: освіта, наука, техніка*. 2021. Т. 3, № 11. С. 16–30. URL: <https://csecurity.kubg.edu.ua/index.php/journal/issue/view/14>
88. Казарян А. Г., Теслюк В. М., Коваль В. Я. Використання функції розпізнавання облич для контролю доступу користувачів та автоматизованого управління налаштувань приладів «розумного» будинку. *Моделювання та інформаційні технології*. 2018. Вип. 83. С. 180–185. URL: [http://nbuv.gov.ua/UJRN/Mtit\\_2018\\_83\\_24](http://nbuv.gov.ua/UJRN/Mtit_2018_83_24)

89. Сидоренко А. В., Шакинко И. В., Сидоренко Ю. В. Алгоритм шифрования изображений с использованием двумерных хаотических отображений. *Системный анализ и прикладная информатика*, 2016. №2. С. 44–49. URL: <https://www.twirpx.com/file/2113567/>
90. Pingguang Cheng, Huaqian Yang, Pengcheng Wei, Wei Zhang. A fast image encryption algorithm based on chaotic map and lookup table. *Nonlinear Dynamics*. 2015. Vol. 79, No 3. P. 2121–2131. URL: <https://www.infona.pl/resource/bwmeta1.element.springer-ee632797-3532-34a0-a56f-5d077d48f0b7>
91. Торубка Т.В., Пуйда В.Я., Пищак І.І. Дослідження алгоритму кореляції для стеження літальними апаратами за їх візуальними зображеннями. *Комп'ютерні системи та мережі*. 2010. №688. С. 214–218. URL: <http://science.lpnu.ua/uk/csn/vsi-vypusky/nomer-688-2010/doslidzhennya-algorytmu-korelyaciyi-dlya-stezhennya-litalnymy>
92. Смирнов А.А., Сахнюк П.А., Саиег Т.Х., Васильченко А.С., Ярошук А.А. Оценка помехоустойчивости каналов связи с замираниями при интеграции нейронной сети. *Проектирование и технология электронных средств*. 2019, №2. С. 33–38. URL: <https://www.elibrary.ru/item.asp?id=41583133>
93. Пятницкий И. А. Применение нейронных сетей в шифровании. Безопасность информационного пространства. 2017: XVI Всероссийская научно-практическая конференция студентов, аспирантов, молодых ученых. Екатеринбург, 2017. Екатеринбург: Изд-во Урал. ун-та, 2018. С. 44–46. URL: <http://hdl.handle.net/10995/65577>
94. R. Hecht-Nielsen. Kolmogorov's Mapping Neural Network Existence Theorem. *Mathematics*. Hecht-Nielsen Neurocomputer Corporation. 1987. URL: <https://cs.uwaterloo.ca/~y328yu/classics/Hecht-Nielsen.pdf>
95. Колмыков М. В., Ручкин В. Н. Применение нейронной сети для фрактального сжатия изображений. *Цифровая Обработка Сигналов*. 2010. №1. С. 51–52. URL: <http://www.dsps.ru/journals/jo-110.php>



96. Нейрокомпьютеры в системах обработки изображений. Кн. 7: Коллективная монография / Общая ред. А. И. Галушкина. М.: Радиотехника, 2003. 192 с. URL: [https://iu4.ru/knigi/2001/2003\\_neuro\\_img.pdf](https://iu4.ru/knigi/2001/2003_neuro_img.pdf)
97. Ватолин Д., Ратушняк А., Смирнов М., Юкин В. Методы сжатия данных. Устройство архиваторов, сжатие изображений и видео. М.: ДИАЛОГ-МИФИ, 2003. 384 с. URL: [https://www.compression.ru/book/pdf/compression\\_methods\\_full\\_scanned.pdf](https://www.compression.ru/book/pdf/compression_methods_full_scanned.pdf)
98. Giovanni Motta, Francesco Rizzo, James A. Storer. Hyperspectral Data Compression. Springer, 2006. 430 p. URL: <https://www.amazon.com/Hyperspectral-Data-Compression-Giovanni-Motta-ebook/dp/B000VHYKDA>
99. Cagnazzo M., Cicala L., Poggi G., Verdoliva L. Low-complexity compression of multispectral images based on classified transform coding. *Signal Processing: Image Communication*. 2006. Vol. 21. P. 850–861. URL: <https://perso.telecom-paristech.fr/cagnazzo/publicazioni/pdf/J22.pdf>
100. Kiely A., Klimesh M., Xie H., Aranki N. ICER-3D: A Progressive Wavelet-Based Compressor for Hyperspectral Images. *The Interplanetary Network Progress Report*. 2006. P. 142–164. URL: [https://ipnpr.jpl.nasa.gov/progress\\_report/42-164/164A.pdf](https://ipnpr.jpl.nasa.gov/progress_report/42-164/164A.pdf)
101. Lena Chang. Multispectral Image Compression Using Eigen-region-based Segmentation. *Pattern Recognition*. 2004. Vol. 37, No 6. P. 1233–1243. URL: <https://ieeexplore.ieee.org/document/977091>
102. Пенроуз Р. Тени разума: в поисках науки о сознании. Москва–Ижевск: ИКИ, 2005. 690 с. URL: <http://alpha.sinp.msu.ru/~panov/Penrose-Shadows.pdf>
103. Stuart R Hameroff. Quantum coherence in microtubules: A neural basis for emergent consciousness? *Journal of consciousness studies*. 1994. Vol. 1. P. 91–118. URL: <http://quantum-mind.org/sites/default/files/Quantum%20Coher%20in%20Microtub%20A%20Neural%20Basis%20for%20Emergent%20Consc%20JCS%201994.p>

104. Lytvyn V., Peleshchak I., Peleshchak R. The compression of the input images in neural network that using method diagonalization the matrices of synaptic weight connections. *2017 2nd International conference on advanced information and communication technologies (AICT)*. 2017. P. 66–70. URL: <https://ieeexplore.ieee.org/document/8020067>
105. Lytvyn V., Peleshchak I., Peleshchak R. Increase the speed of detection and recognition of computer attacks in combined diagonalized neural networks. *2017 4th International scientific-practical conference “Problems of infocommunications. science and technology” (PIC S&T)*. 2017. P. 152–155. URL: <https://ieeexplore.ieee.org/document/8246370>
106. Peleshchak R., Lytvyn V., Peleshchak I., Olyvko R., Korniak J. Decision making model based on neural network with diagonalized synaptic connections. *Advances in Intelligent Systems and Computing*, 2019. Vol. 853. P. 321–329. URL: [https://link.springer.com/chapter/10.1007/978-3-319-99996-8\\_29](https://link.springer.com/chapter/10.1007/978-3-319-99996-8_29)
107. Ackley D. H., Hinton G. E., and Sejnowski T. J. A Learning Algorithm for Boltzmann Machines. *Cognitive Science*. 1985. Vol. 9. P. 147–169. URL: <https://www.cs.toronto.edu/~hinton/absps/cogscibm.pdf>
108. Hinton, G. E. and Sejnowski, T. J. Learning and relearning in Boltzmann machines. In Rumelhart, D. E. and McClelland, J. L., editors, *Parallel Distributed Processing: Explorations in the Microstructure of Cognition*. 1986. Vol. 1. P. 282–317. URL: [https://www.researchgate.net/profile/Terrence\\_Sejnowski/publication/242509302\\_Learning\\_and\\_relearning\\_in\\_Boltzmann\\_machines/links/54a4b00f0cf256bf8bb327cc.pdf](https://www.researchgate.net/profile/Terrence_Sejnowski/publication/242509302_Learning_and_relearning_in_Boltzmann_machines/links/54a4b00f0cf256bf8bb327cc.pdf)
109. D. V. Alexeev. Neural network approximation of several variable functions. *Fundamental and Applied Mathematics. The Conference «Intelligent Systems and Computer Science»*. 2009. Vol. 15. P. 9–21. URL: <http://mech.math.msu.su/~fpm/eng/k09/k093/k09303h.htm>
110. Peleshchak R., Lytvyn V., Peleshchak I., Doroshenko M., Olyvko R. Hechth–Nielsen theorem for a modified neural network with diagonal synaptic



- connections. *Mathematical Modeling and Computing*. 2019. Vol. 6, No 1. P. 101–108. URL: <http://science.lpnu.ua/mmc/all-volumes-and-issues/volume-6-number-1-2019/hechth-nielsen-theorem-modified-neural-network>
111. Шумский С.А. Машинный интеллект. Очерки по теории машинного обучения и искусственного интеллекта. М.: РИОР, 2019. 340 с. URL: <https://riorpub.com/en/storage/viewWindow/39651>
112. Callan, R. Basic Concepts of Neural Networks. Moscow, *Williams Publishing House*, 2001. 288 p. URL: [http://www.immsp.kiev.ua/postgraduate/Biblioteka\\_trudy/OsnovnKoncepNejronSetejKallan2001.pdf](http://www.immsp.kiev.ua/postgraduate/Biblioteka_trudy/OsnovnKoncepNejronSetejKallan2001.pdf)
113. Терейковский И. А. Оптимизация структуры многослойного персептрона в системах защиты компьютерной информации. *Захист інформації, НАУ*: Київ. 2012. Т.14. №3. С. 36–40. URL: <https://www.elibrary.ru/item.asp?id=19427466>
114. Kyrchei Ivan. Advances in Linear Algebra Research (Mathematics Research Developments). *Nova Science Pub Inc; UK ed. Edition*. 2015. 353 p. URL: <https://www.amazon.com/Advances-Algebra-Research-Mathematics-Developments/dp/1634635655>
115. Гейдаров П. Ш. Нейронные сети прямого распространения с вычисляемыми параметрами. *Информационные Технологии*. 2017. №. 7. С. 543–552. URL: <http://novtex.ru/IT/it2017/number07.html>
116. Lytvyn V., Peleshchak I., Peleshchak R., Kuzyk O. Size optimization of the multilayer neural network in the framework of the nonlinear generalized error model. *2019 9th International conference on advanced computer information technologies (ACIT)*. 2019. P. 221–225. URL: <https://ieeexplore.ieee.org/abstract/document/8779994>
117. Цимбал Ю. В. Нейромережевий метод симетричного шифрування даних. *Вісник Національного університету «Львівська політехніка». Серія: Інформаційні системи та мережі*. 2018. № 901. С. 118-122. URL: [http://nbuv.gov.ua/UJRN/VNULPICM\\_2018\\_901\\_15](http://nbuv.gov.ua/UJRN/VNULPICM_2018_901_15).

118. Дорогов А. Ю. Теория и проектирование быстрых перестраиваемых преобразований и слабосвязанных нейронных сетей. СПб.: Политехника, 2014. 344 с. URL: <https://litportal.ru/avtory/a-u-dorogov/kniga-teoriya-i-proektirovanie-bystryh-perestraivaemyh-preobrazovaniy-i-slabosvyazannyh-neyronnyh-setey-730195.html>
119. Lytvyn V., Peleshchak I., Peleshchak R., Vysotska V. Information encryption based on the synthesis of a neural network and AES algorithm. *2019 3rd International conference on advanced information and communications technologies (AICT)*. 2019. P. 447–450. URL: <https://ieeexplore.ieee.org/document/8847896>
120. М.П. Минеев, В.Н. Чубариков. Лекции по арифметическим вопросам криптографии. М.: Изд-во «Попечительский совет Механико-математического факультета МГУ им. М. В. Ломоносова», 2010. 186 с. URL: <http://docplayer.ru/28353736-Lekcii-po-arifmeticheskim-voprosam-kriptografii.html>
121. Пелещак Р., Литвин В., Пелещак І., Висоцька В. Розроблення штучної нейронної мережі з осциляторними нейронами для розпізнавання спектральних образів. *Вісник Національного університету «Львівська політехніка». Серія: Інформаційні системи та мережі*. 2020. Вип. 7. С. 16–23. URL: <http://science.lpnu.ua/sites/default/files/journal-paper/2020/feb/21017/200122infsyst2-18-25.pdf>
122. Peleshchak I., Peleshchak R., Lytvyn V., Kopka J., Wrzesien M., Korniak J., Kolbusz J., Rozycki P. Spectral image recognition using artificial dynamic neural network in information resonance mode. *Advances in Intelligent Systems and Computing*. 2020. Vol. 1193. P. 313–322. URL: [https://link.springer.com/chapter/10.1007/978-3-030-51186-9\\_22](https://link.springer.com/chapter/10.1007/978-3-030-51186-9_22)
123. Peleshchak R., Peleshchak I., Vysotska V. Models for recognizing multispectral images based on neural network technologies. *Beau Bassin: LAP Lambert Academic Publishin*. 2020. 152 p. URL: <https://www.lap->

- [publishing.com/catalog/details/store/cn/book/978-620-3-19797-6/methods-for-recognizing-multispectral-images-based-on-neural-networks?search=Vysotska](http://publishing.com/catalog/details/store/cn/book/978-620-3-19797-6/methods-for-recognizing-multispectral-images-based-on-neural-networks?search=Vysotska)
124. Холманский. А.С. Моделирование физики мозга. *Квантовая Магия*. 2006. № 3. С. 3126–3155. URL: <http://quantmagic.narod.ru/volumes/VOL332006/p3126.html>
125. Смит К. Биология сенсорных систем. М.: БИНОМ / Лаборатория знаний, 2013. 583 с. URL: <https://speakagain.ru/biblioteka-professionala/smit-k-biologiya-sensornyx-sistem/>
126. Slyadnikov E. E. Physical model and the associative memory of a cytoskeleton microtubule as a system of dipoles. *Technical Physics*. 2007. Vol. 52, P. 898–906. URL: <https://link.springer.com/article/10.1134/S1063784207070110>
127. Alexey N. Pavlov, Olga V. Sosnovtseva, Erik Mosekilde, Vadim S. Anishchenko. Extracting dynamics from threshold-crossing interspike intervals: Possibilities and limitations. *Phys. Rev. E*. 2000. Vol. 61. P. 5033 URL: <https://journals.aps.org/pre/abstract/10.1103/PhysRevE.61.5033>
128. Павлов А.Н. Вейвлет-анализ и примеры его применения. *Изв. вузов «ПНД»*. 2009. Т.17. С. 99–110. URL: <https://cyberleninka.ru/article/n/veyvlet-analiz-i-primery-ego-primeneniya/viewer>
129. Сугаков В.Й. Основы синергетики. Киев 2001. 288 с. URL: <https://www.twirpx.com/file/1722277/>
130. Боголюбов Н. Н. Асимптотические методы в теории нелинейных колебаний. М.: Наука. 1974. 504 с. URL: <https://ikfia.ysn.ru/wp-content/uploads/2018/01/BogolyubovMitropolskij1974ru-1.pdf>
131. Пелешак Р. М., Литвин В. В., Пелешак І. Р. Динаміка нелінійного осциляторного нейрона при дії зовнішнього нестационарного сигналу. *Радіоелектроніка, інформатика, управління*. 2017. № 4. С. 97–105. URL: <http://ric.zntu.edu.ua/article/view/126359>
132. Lytvyn V., Vysotska V., Peleshchak I., Rishnyak I., Peleshchak R. Time dependence of the output signal morphology for nonlinear oscillator neuron based

- on Van der Pol model. *International Journal of Intelligent Systems and Applications*. 2018. Vol. 10, No. 4. P. 8–17. URL: <http://www.mecspress.org/ijisa/ijisa-v10-n4/v10n4-2.html>
133. Tim Sauer. Reconstruction of dynamical systems from interspike intervals. *Phys. Rev. Lett.*, 1994. Vol. 72, P. 3811. URL: <https://journals.aps.org/prl/abstract/10.1103/PhysRevLett.72.3811>
134. Racicot D. M., Lonytin A. Interspike interval attractors from chaotically driven neuron models. *Physic D: Nonlinear Phenomena*. 1997. Vol. 104. P. 184–204. URL: <https://www.sciencedirect.com/science/article/abs/pii/S0167278997002960>
135. Rolando Castro, Tim Sauer. Correlation dimension of attractors through interspike intervals. *Phys. Rev. E*. 1997. Vol. 55. P. 287. URL: <https://journals.aps.org/pre/abstract/10.1103/PhysRevE.55.287>
136. Sauer T. Reconstruction of integrate-and-fire dynamics. *Nonlinear Dinamics and Time Series*. 1997. Vol. 11. P. 63–75. URL: <http://www.ams.org/books/fic/011/fic011.pdf>
137. Rainer Hegger and Holger Kantz. Embedding of sequences of time intervals. *Max Planck Institut fur Physik komplexer Systeme*. Dresden, Germany, 1997. P. 1–9. URL: <https://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.30.8550&rep=rep1&type=pdf>
138. Rolando Castro, Tim Sauer. Chaotic Stochastic Resonance: Noise-Enhanced Reconstruction of Attractors. *Phys. Rev. Lett.*. 1997. Vol. 79. P. 1030. URL: <https://journals.aps.org/prl/abstract/10.1103/PhysRevLett.79.1030>
139. Павлов А. Н., Храмов А. Е., Короновский А. А., Сытникова Е. Ю., Макаров В. А., Овчинников А. А. Вейвлет-анализ в нейродинамике. *Успехи физических наук*. 2012. Т. 182, № 9. С. 905–939. URL: <https://www.academia.edu/12753076>
140. Henry C. Tuckwell. Introduction to Theoretical Neurobiology: Volume 2, Nonlinear and Stochastic Theories (Cambridge Studies in Mathematical Biology,

- Series Number 8) 1st Edition. 1988. 292 p. URL: <https://www.amazon.com/Introduction-Theoretical-Neurobiology-Stochastic-Mathematical/dp/0521352177>
141. Bay J. S., Hemami H. Modeling of a neural pattern generator with coupled nonlinear oscillators. *IEEE Trans Biomed Eng.* 1987. Vol. 34. P. 297–306. URL: <https://pubmed.ncbi.nlm.nih.gov/3332778/>
142. Божокин С. В. Непрерывное вейвлет-преобразование и точно решаемая модель нестационарных сигналов. *ЖТФ.* 2012. Т. 82, вып. 7. С.8–13. URL: <http://journals.ioffe.ru/articles/viewPDF/10642>
143. A. Grossmann and J. Morlet. Decomposition of Hardy Functions into Square Integrable Wavelets of Constant Shape. *SIAM Journal on Mathematical Analysis Volume.* 1984. Vol. 15, No 4. P. 723–736. URL: <https://epubs.siam.org/doi/10.1137/0515056>
144. Charles K. Chui. Wavelets: A Mathematical Tool for Signal Analysis (Siam Monographs on Mathematical Modeling and Computation). *Society for Industrial and Applied Mathematics.* 1987. 210 p. URL: <https://www.amazon.com/Wavelets-Mathematical-Monographs-Computation-1987-01-01/dp/B019TLINW2>
145. Peleshchak R., Lytvyn V., Bihun O., Peleshchak I. Structural transformations of incoming signal by a single nonlinear oscillatory neuron or by an artificial nonlinear neural network. *International Journal of Intelligent Systems and Applications.* 2019. Vol. 11, No 8. P. 1–10. URL: <http://www.mecspress.org/ijisa/ijisa-v11-n8/v11n8-1.html>
146. Литвин В. В., Пелешак Р. М., Пелешак І. Р. Шифрування інформації за допомогою ланцюга нелінійних осциляторних нейронів. *Матеріали 2-гої Міжнародної науково-практичної конференції «Проблеми науково-технічного та правового забезпечення кібербезпеки у сучасному світі «ПНПЗК-2017».* Харків, 2017. С. 77. URL: [http://repository.kpi.kharkov.ua/bitstream/KhPI-Press/40634/1/Conference NTU KhPI 2017 Kiberbezpeka.pdf](http://repository.kpi.kharkov.ua/bitstream/KhPI-Press/40634/1/Conference%20NTU%20KhPI%202017%20Kiberbezpeka.pdf)

147. Скурихин А.Н. Генетические алгоритмы. Новости искусственного интеллекта. 1995. № 4. С. 6–46. URL: <https://biologo.ru/index2.html>
148. Васильев В. Н., Павлов А. В. Оптические технологии искусственного интеллекта Том I. СПб: СПб ГУ ИТМО, 2008. 81 с. URL: [https://books.ifmo.ru/book/363/opticheskie\\_tehnologii\\_iskusstvennogo\\_intellekta\\_tom\\_I.htm](https://books.ifmo.ru/book/363/opticheskie_tehnologii_iskusstvennogo_intellekta_tom_I.htm)
149. Ярославский Л.П. Цифровая обработка сигналов в оптике и голографии: Введение в цифровую оптику. М.: «Радио и связь», 1987. 296 с. URL: [https://www.studmed.ru/yaroslavskiy-lp-cifrovaya-obrabotka-signalov-v-optike-i-golografii-vvedenie-v-cifrovuyu-optiku\\_0735264cc0d.html](https://www.studmed.ru/yaroslavskiy-lp-cifrovaya-obrabotka-signalov-v-optike-i-golografii-vvedenie-v-cifrovuyu-optiku_0735264cc0d.html)
150. Андреев С. Н., Фирсов В. Г., Павлович А. В. Нейроголографический метод анализа мультиспектральных аэрофотоизображений. XXIII международная научно-техническая конференция «Радиолокация, навигация, связь». 2017. Т.2. С.405–413. URL: <https://rlnc.ru/sites/default/files/conference/rlnc2017-proc-2.pdf>
151. Котов В. Б. Динамическая нейросеть с локальными связями как пространственно-временная ассоциативная память. *Радиотехника и электроника*. 2002. Т. 47. С. 1083–1090. URL: <https://www.elibrary.ru/contents.asp?id=33592276>
152. Холманский А. С. Моделирование физики мозга. *Квантовая Магия*, 2006. Т. 3, вып. 3. С.3126–3155. URL: <http://quantmagic.narod.ru/volumes/VOL332006/p3126.html>
153. Кульчин Ю. Н., Ким А. Ю., Ноткин Б. С., Люхтер А. Б. Обработка сигналов распределенной волоконно-оптической сети для распознавания динамических образов с применением нейронных сетей. *Информационные Технологии*. 2015. № 4. С. 312–318. <http://novtex.ru/IT/it2015/number04.html>
154. Subbotin, S. A. The Neuro-Fuzzy Network Synthesis With The Ranking And Specific Encoding Of Features For The Diagnosis And Automatic Classification On Precedents. *Radio Electronics, Computer Science, Control*.

*Neuroinformatics and intelligent systems*. 2016. No 1. P. 50–57. URL:  
<http://ric.zntu.edu.ua/article/view/66500/61804>

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

Усі наукові результати, викладені у дисертаційній роботі, отримані автором особисто.

*Наукові праці, в яких опубліковані основні наукові результати дисертації*  
*Статті у фахових виданнях України, які входять до міжнародних наукометричних баз:*

1. Пелешак Р. М., Литвин В. В., **Пелешак І. Р.** Динаміка нелінійного осциляторного нейрона при дії зовнішнього нестационарного сигналу. *Радіоелектроніка, інформатика, управління*. 2017. №4. С. 97–105. *Особистий внесок здобувача: запропоновано нелінійну математичну модель динаміки осциляторного нейрона з урахуванням його порогового ефекту при дії на нейрон зовнішніх нестационарних сигналів.*
2. Peleshchak R., Lytvyn V., **Peleshchak I.**, Doroshenko M., Olyvko R. Hechth–Nielsen theorem for a modified neural network with diagonal synaptic connections. *Mathematical Modeling and Computing*, 2019. Vol. 6(1). P. 101–108. *Особистий внесок здобувача: доведено модифіковану теорему Хехт–Нільсена для тришарової нейронної мережі з архітектурою, яка має тільки діагональні синаптичні зв'язки між нейронами, що дає змогу апроксимувати функцію від  $n$  змінних, з заданою точністю  $\varepsilon > 0$ , за допомогою однієї операції агрегування.*

*Статті у фахових виданнях України:*

3. Пелешак Р. М., Литвин В. В., **Пелешак І. Р.**, Висоцька В. А. Розробка штучної нейронної мережі з осциляторними нейронами для розпізнавання спектральних образів. *Вісник Національного університету «Львівська політехніка»*. Інформаційні системи та мережі, 2020. Vol. 7. P. 16–23. *Особистий внесок здобувача: запропоновано новий тип штучної нейронної*



мережі з осциляторними нейронами, що дає змогу розпізнавати сигнали з амплітудою співмірною рівню шуму внаслідок інформаційного резонансу.

Статті у наукових періодичних виданнях інших держав:

4. Peleshchak R., Lytvyn V., Bihun O., **Peleshchak I.** Structural transformations of incoming signal by a single nonlinear oscillatory neuron or by an artificial nonlinear neural network. *International Journal of Intelligent Systems and Applications (IJISA)*, 2019. Vol. 11(8). P. 1–10. *Особистий внесок здобувача: запропоновано метод кодування інформації (зміну морфології вхідного сигналу) нелінійним осциляторним нейроном на основі частотної модуляції.*

Статті у наукових періодичних виданнях інших держав, які входять до міжнародних наукометричних баз:

5. Vasyl Lytvyn, Victoria Vysotska, **Ivan Peleshchak**, Ihor Rishnyak, Roman Peleshchak. Time Dependence of the Output Signal Morphology for Nonlinear Oscillator Neuron Based on Van der Pol Model. *International Journal of Intelligent Systems and Applications (IJISA)*, 2018. Vol. 10(4). P. 8–17. *Особистий внесок здобувача: запропоновано спосіб розв'язку нелінійного неоднорідного диференційного рівняння другого порядку з квадратичною нелінійністю шуканої функції при першій похідній методом послідовних наближень (у наближенні Крилова-Боголюбова-Митропольського).*
6. Peleshchak R., Lytvyn V., **Peleshchak I.**, Olyvko R., Korniak J. Decision making model based on neural network with diagonalized synaptic connections. *Advances in Intelligent Systems and Computing*, 2019. Vol. 853. P. 321–329. *Особистий внесок здобувача: запропоновано модель прийняття рішень, що базується на архітектурі тришарового перцептрона з діагоналізованими синаптичними зв'язками між нейронами вхідного та прихованого шарів.*
7. Lytvyn V., Vysotska V., Shakhovska N., Mykhailyshyn V., Medykovskyy M., **Peleshchak I.**, Fernandes V., Peleshchak R., Shcherbak S. A smart home system development. *Advances in Intelligent Systems and Computing*, 2020. Vol. 1080. P. 804–830. *Особистий внесок здобувача: розроблено програмне забезпечення для роботи системи «розумного» будинку.*

8. Makara S., Chyrun L., Burov Y., Rybchak Z., **Peleshchak I.**, Peleshchak R., Holoshchuk R., Kubinska S., Dmytriv A. An intelligent system for generating end-user symptom recommendations based on machine learning technology. *CEUR Workshop Proceedings*, 2020. Vol. 2604. P. 844–883. *Особистий внесок здобувача: розроблено програмне забезпечення для роботи системи вибору та придбання ліків.*
9. **Ivan Peleshchak**, Roman Peleshchak, Vasyl Lytvyn, Jan Kopka, Mariusz Wrzesien, Janusz Korniak, Janusz Kolbusz, Pawel Rozycki. Spectral Image Recognition Using Artificial Dynamic Neural Network in Information Resonance Mode. *A2IA 2020: International Conference on Artificial Intelligence and Industrial Applications*, 2020. P. 313–322. *Особистий внесок здобувача: розроблено метод розпізнавання мультиспектральних образів за допомогою осциляторної нейронної мережі на основі інформаційного резонансу.*

*Матеріали міжнародних наукових та науково-практичних конференцій, збірники яких входять до міжнародних наукометричних баз:*

10. Vasyl Lytvyn, **Ivan Peleshchak**, Roman Peleshchak. The compression of the input images in neural network that using method diagonalization the matrices of synaptic weight connections. *2017 2nd International Conference on Advanced Information and Communication Technologies (AICT)*, 2017. P. 66–70. *Особистий внесок здобувача: розроблено метод стиснення інформації внаслідок діагоналізації матриці вагових синаптичних зв'язків нейромережі.*
11. Vasyl Lytvyn, **Ivan Peleshchak**, Roman Peleshchak. Increase the speed of detection and recognition of computer attacks in combined diagonalized neural networks. *2017 4th International Scientific-Practical Conference Problems of Infocommunications. Science and Technology (PIC S&T)*, 2017. P. 152–155. *Особистий внесок здобувача: запропоновано метод підвищення швидкості розпізнавання комп'ютерних атак внаслідок комбінування діагоналізованих нейронних мереж.*

12. Vasyl Lytvyn, **Ivan Peleshchak**, Roman Peleshchak, Roman Holoshchuk. Detection of multispectral input images using nonlinear artificial neural networks. *2018 14th International Conference on Advanced Trends in Radioelectronics, Telecommunications and Computer Engineering (TCSET)*, 2018. P. 119–122. *Особистий внесок здобувача: запропоновано метод розпізнавання мультиспектральних образів за допомогою нейронної мережі з нелінійними осциляторними нейронами на основі інформаційного резонансу.*
13. Lytvyn V., **Peleshchak I.**, Peleshchak R., Kuzyk O. Size optimization of the Multilayer Neural Network in the Framework of the Nonlinear Generalized Error Model. *2019 9th International Conference on Advanced Computer Information Technologies*, 2019. P. 221–225. *Особистий внесок здобувача: запропоновано спосіб оптимізації структури багатошарової нейронної мережі на основі мінімізації нелінійної узагальненої похибки, яка базується на принципі мінімальної довжини опису.*
14. Lytvyn V., **Peleshchak I.**, Peleshchak R., Vysotska V. Information Encryption Based on the Synthesis of a Neural Network and AES Algorithm. *2019 3rd International Conference on Advanced Information and Communications Technologies*, 2019. P. 447–450. *Особистий внесок здобувача: запропоновано систему шифрування інформації на основі синтезу діагоналізованої нейронної мережі та алгоритму AES.*

*Колективна монографія:*

15. Roman Peleshchak, **Ivan Peleshchak**, Victoria Vysotska. Methods for recognizing multispectral images based on neural networks. *LAP Lambert Academic Publishing*, 2020. 152 p. *Особистий внесок здобувача: запропоновано метод розпізнавання мультиспектральних образів за допомогою осциляторної нейронної мережі на основі інформаційного резонансу.*

*Патент на корисну модель:*

16. Патент на корисну модель. Пелещак Р. М., Литвин В. В., **Пелещак І. Р.** Спосіб шифрування цифрової інформації на основі синтезу діагоналізованої

нейронної мережі та AES. Національний університет «Львівська політехніка». У 2021 01284. № 3320/ЗУ/21. *Особистий внесок здобувача: запропоновано систему шифрування інформації на основі синтезу діагоналізованої нейронної мережі та алгоритму AES.*

*Наукові праці, які додатково відображають наукові результати дисертації:*

17. Zdebskyi P., Vysotska V., Peleshchak R., **Peleshchak I.**, Demchuk A., Krylyshyn M. An application development for recognizing of view in order to control the mouse pointer. *CEUR Workshop Proceedings*, 2019. V. 2386. P. 55–74. *Особистий внесок здобувача: розроблено програмне забезпечення для розпізнавання точки зору користувача з метою управління вказівником миші.*
18. Lytvyn V., Vysotska V., Mykhailyshyn V., **Peleshchak I.**, Peleshchak R., Kohut I. Intelligent system of a smart house. *2019 3rd International Conference on Advanced Information and Communications Technologies*, 2019. P. 282–287. *Особистий внесок здобувача: розроблено програмне забезпечення для роботи системи «розумного» будинку.*
19. Lytvyn V., Vysotska V., **Peleshchak I.**, Basyuk T., Kovalchuk V., Kubinska S., Rusyn B., Pohreliuk L., Chyrun L., Salo T. Identifying Textual Content Based on Thematic Analysis of Similar Texts in Big Data. *IEEE 2019 14th International Scientific and Technical Conference on Computer Sciences and Information Technologies*, 2019. P. 84–91. *Особистий внесок здобувача: розроблено програмне забезпечення для виявлення змісту тексту на основі тематичного аналізу.*
20. Bekesh R., Chyrun L., Kravets P., Demchuk A., Matseliukh Y., Batiuk T., **Peleshchak I.**, Bigun R., Maiba I. Structural modeling of technical text analysis and synthesis processes. *CEUR Workshop Proceedings*, 2020. Vol. 2604. P. 562–589. *Особистий внесок здобувача: розроблено програмне забезпечення для автоматизації процесів аналізу та синтезу природних текстів.*
21. Husak V., Lozynska O., Karpov I., **Peleshchak I.**, Chyrun S., Vysotskyi A. Information system for recommendation list formation of clothes style image

selection according to user's needs based on NLP and chatbots. *CEUR Workshop Proceedings*, 2020. Vol. 2604. P. 788–818. *Особистий внесок здобувача: розроблено програмне забезпечення для роботи чат-бота на базі месенджерів Telegram.*

## Акти впровадження результатів дисертації



### МІНІСТЕРСТВО ОСВІТИ І НАУКИ УКРАЇНИ ЧЕРНІВЕЦЬКИЙ НАЦІОНАЛЬНИЙ УНІВЕРСИТЕТ ІМЕНІ ЮРІЯ ФЕДЬКОВИЧА

вул. М.Коцюбинського, 2, м.Чернівці, 58002, тел. (0372) 584811, факс (0372) 552914,  
E-mail: rector@chnu.edu.ua, код ЄДРПОУ 02071240

Від 10.06.2021 № 06/17-1223 На № \_\_\_\_\_ Від \_\_\_\_\_



ЗАТВЕРДЖУЮ  
Проректор  
з наукової роботи  
Чернівецького національного університету  
імені Юрія Федьковича  
д.т.н. А.П.Саміла

АКТ

про впровадження результатів дисертації Пелешака Івана Романовича  
«Система розпізнавання мультиспектральних образів на основі осциляторних нейронних мереж», представленої на здобуття наукового ступеня доктора філософії за спеціальністю 124 «Системний аналіз» (галузь знань 12 Інформаційні технології)

Наукові положення, що складають наукову новизну дисертаційного дослідження Пелешака І.Р., впроваджені в освітній процес у Чернівецькому національному університеті імені Юрія Федьковича упродовж 2020 – 2021 н. р. при підготовці здобувачів першого (бакалаврського) та другого (магістерського) рівнів вищої освіти за спеціальністю 122 Комп'ютерні науки та інформаційні технології (Спеціалізація – Інтелектуальний аналіз даних в комп'ютерних інформаційних системах).

Наукові результати є актуальними при формуванні вищої освіти теоретичних знань та практичних умінь і навичок, необхідних для вирішення різноманітних завдань управління складними динамічними процесами різної природи засобами сучасних програмних комплексів і систем підтримки прийняття рішень.

Результати дисертаційного дослідження дозволили розширити й конкретизувати робочі програми таких навчальних дисциплін:

- за освітньою програмою першого (бакалаврського) рівня вищої освіти освітні компоненти: «Системний аналіз», «Інтелектуальний аналіз сигналів та зображень»;
- за освітньою програмою другого (магістерського) рівня вищої освіти освітні компоненти: «Комп'ютерний зір, розпізнавання та класифікація в системах штучного інтелекту», «Машинне навчання й технології обчислювального інтелекту».

Акт про впровадження наукових результатів дисертаційного дослідження І.Р.Пелешака «Система розпізнавання мультиспектральних образів на основі осциляторних нейронних мереж», здобувача вищої освіти ступеня доктора філософії за спеціальністю 124 Системний аналіз галузі знань 12 Інформаційні технології затверджено на засіданні кафедри комп'ютерних наук відділу комп'ютерних технологій Інституту фізико-технічних та комп'ютерних наук Чернівецького національного університету імені Юрія Федьковича (протокол № 12 від «26» травня 2021 р.).

Завідуюча кафедрою комп'ютерних наук  
доктор філософії  
професор

Гідліс Ушенка 20.0 засвідчую  
Начальник відділу кадрів Чернівецького національного університету імені Юрія Федьковича  
М.С.Сукма  
" 10 " 06 2021 р

Ю.О.Ушенко

Чернівці, ЧНУ, зав. Б-079, т. 4000



ЗАТВЕРДЖУЮ  
Проректор  
з наукової роботи  
Національного університету  
«Львівська політехніка»  
В. Демидов  
07.05.2021 р.

АКТ


про використання результатів дисертації Пелешака Івана Романовича  
«Система розпізнавання мультиспектральних образів на основі осциляторних нейронних  
мереж», представленої на здобуття наукового ступеня доктора філософії  
при виконанні науково-дослідної роботи за кошти державного бюджету

Комісія у складі начальника науково-дослідної частини д.т.н, ст.досл. Р. В. Небесного, завідувача кафедри інформаційних систем та мереж д.т.н., проф. В. В. Литвина, завідувачки відділу науково-організаційного супроводу наукових досліджень к.т.н. Г. В. Лазько та начальниці планово-фінансової групи Т. М. Чулой підтверджують цим актом, що результати дисертації І. Р. Пелешака «Система розпізнавання мультиспектральних образів на основі осциляторних нейронних мереж» використано при виконанні державної науково-дослідної роботи за кошти державного бюджету «Система підтримки прийняття рішень розпізнавання мультиспектральних образів на основі технологій машинного навчання та онтологічного підходу», номер державної реєстрації 0120U102203.

В результаті досліджень, виконаних І. Р. Пелешаком:

- розроблено нелінійну модель оптимізації розміру багатопарової нейронної мережі в межах узагальненої похибки;
- розроблено метод розпізнавання мультиспектральних образів на основі осциляторних нейронних мереж;
- розроблено систему шифрування на основі синтезу алгоритму AES та діагоналізованої нейронної мережі.

Голова комісії:  
Начальник НДЧ, д.т.н, ст.досл.

  
Р. В. Небесний

Члени комісії:  
Завідувач кафедри  
Інформаційних систем та мереж

  
В. В. Литвин

Завідувачка відділу науково-організаційного  
супроводу наукових досліджень

  
Г. В. Лазько

Начальниця планово-фінансової групи

  
Т. М. Чулой





ЗАТВЕРДЖУЮ  
Проректор  
з наукової роботи  
Національного університету  
«Львівська політехніка»  
В. Демидов  
2021 р.

АКТ


про використання результатів дисертації Пелешака Івана Романовича  
«Система розпізнавання мультиспектральних образів на основі осциляторних нейронних  
мереж», представленої на здобуття наукового ступеня доктора філософії  
при виконанні науково-дослідної роботи за кошти державного бюджету

Комісія у складі начальника науково-дослідної частини д.т.н, ст.досл. Р. В. Небесного, завідувача кафедри інформаційних систем та мереж д.т.н., проф. В. В. Литвина, завідувачки відділу науково-організаційного супроводу наукових досліджень к.т.н. Г. В. Лазько та начальниці планово-фінансової групи Т. М. Чулой підтверджують цим актом, що результати дисертації І.Р.Пелешака «Система розпізнавання мультиспектральних образів на основі осциляторних нейронних мереж» використано при виконанні державної науково-дослідної роботи за кошти державного бюджету «Методи та засоби функціонування систем підтримки прийняття рішень на основі онтологій», номер державної реєстрації 0118U000269.

В результаті досліджень, виконаних І. Р. Пелешаком:

- здійснено аналіз динаміки нелінійного осциляторного нейрона при дії зовнішнього нестационарного сигналу;
- доведено модифіковану теорему Хехт-Нільсена для нейронної мережі з діагональними синаптичними зв'язками;
- розроблена система підтримки прийняття рішень на основі діагоналізованої нейронної мережі.

Голова комісії:  
Начальник НДЧ, д.т.н, ст.досл.

  
Р. В. Небесний

Члени комісії:  
Завідувач кафедри  
Інформаційних систем та мереж

  
В. В. Литвин

Завідувачка відділу науково-організаційного  
супроводу наукових досліджень

  
Г. В. Лазько

Начальниця планово-фінансової групи

  
Т. М. Чулой



## Повний код програми нейронної мережі

```

import sys
import math
import os.path
import json
import random
import time

class NeuralNetwork:
    def __init__(self):
        try:
            with open('app/config/config.json') as f:
                self.config = json.load(f)
        except:
            print("Error: Configuration file is not found. (app/config/config.json)")
            exit()

        try:
            with open('app/structure/structure.json') as f:
                self.structure = json.load(f)
        except:
            self.structure = {"w": [], "v": []}
            for i in range(self.config["neurons"]["hidden"]):
                temp = []
                for j in range(self.config["neurons"]["input"]):
                    temp.append(random.random()*(1-self.config["delta"])+self.config["delta"])
                self.structure["w"].append(temp)

            temp = []
            for i in range(self.config["neurons"]["hidden"]):
                temp.append(random.random()*(1-self.config["delta"])+self.config["delta"])
            self.structure["v"].append(temp)

            self.save_structure()
            print("- Created new structure -")

    def run(self, input):
        try:
            with open(input) as f:
                data = json.load(f)
        except:
            print("Error: Input file is not found.")
            exit()

        result = []
        for test in data:
            answer = self.run_test(test["input"])
            output = [answer, self.get_result(answer)]
            output.append(self.get_y(test["input"]))
            result.append(output)
        return result

    def train(self, train):
        try:
            with open(train) as f:
                data = json.load(f)
        except:
            print("Error: Input file is not found.")
            exit()

        print("- Training process (error_max: "+str(self.config["error_max"])+") -")

```

```

index = 0
while index < len(data):
    result = self.run_test(data[index]["input"])
    error = self.get_error(result, data[index]["input"])
    if error > self.config["error_max"]:
        print("Test #" + str((index+1)) + " error: " + str(error))
        self.update_structure(data[index]["input"])
        index = 0
    else:
        index += 1

print("- Training is finished.")
self.save_structure()

def save_structure(self):
    try:
        with open('app/structure/structure.json', 'w') as f:
            f.write(json.dumps(self.structure))
    except:
        print("Error: Can not write structure file.")
        exit()

def get_result(self, value):
    if (value - self.config["threshold"]) > 0:
        return 0
    else:
        return 1

def run_test(self, test):
    if len(test["V"]) != len(test["W"]) or len(test["W"]) != self.config["neurons"]["input"]:
        print("Error: Wrong input data.")
        exit()

    result = 0
    for m in range(self.config["neurons"]["hidden"]):
        sum = 0
        for i in range(self.config["neurons"]["input"]):
            w = test["W"][i]**2
            sum += test["V"][i] * ( w / ( 2 * ( (self.structure["w"][m][i]**2 - 4*w )**2 +
16*self.config["delta"]**2*w )**(1/2) ) )
            result += self.structure["v"][0][m] * ( 1 / ( 1 + math.exp( -self.config["betta"] * sum
) ) )
        return result

def get_error(self, result, input):
    return 1/2 * ( self.get_error_value(result, input) )**2

def get_y(self, input):
    y = 1
    n = (self.config["neurons"]["hidden"] * self.config["neurons"]["input"])/2
    c = 0
    for m in range(self.config["neurons"]["hidden"]):
        for i in range(self.config["neurons"]["input"]):
            yi = input["W"][i] - (self.structure["w"][m][i]**2)/(2 * (self.structure["w"][m][i]**2
- 2*self.config["delta"]**2)**(1/2))
            if abs(yi) > self.config["eps"]:
                c += 1
    if c > n:
        y = 0

    return y

def get_error_value(self, result, input):

```

```

return (result - self.config["threshold"] - self.get_y(input))

def update_structure(self, input):
    error = self.get_error_value(self.run_test(input), input)

    for m in range(self.config["neurons"]["hidden"]):
        sum = 0
        for i in range(self.config["neurons"]["input"]):
            w = input["W"][i]**2
            sum += (input["V"][i] * w) / (2 * (16 * self.config["delta"]**2*w +
(self.structure["w"][m][i]**2 - 4*w)**2)**(1/2))

            for i in range(self.config["neurons"]["input"]):
                w = input["W"][i]**2
                Ew = ( -(math.exp(-self.config["beta"] * sum) * self.config["beta"] *
self.structure["v"][0][m] * input["V"][i] * self.structure["w"][m][i] * w *
(self.structure["w"][m][i]**2 - 4*input["W"][i]**2) * error)) / ( (1 + math.exp(-
self.config["beta"] * sum))**2 * (16 * self.config["delta"]**2*w +
(self.structure["w"][m][i]**2 - 4*w)**2)**(3/2) )
                self.structure["w"][m][i] = self.structure["w"][m][i] - self.config["eta"]*Ew

        for m in range(self.config["neurons"]["hidden"]):
            sum = 0
            for i in range(self.config["neurons"]["input"]):
                w = input["W"][i]**2
                sum += (input["V"][i] * w) / (2 * (16 * self.config["delta"]**2*w +
(self.structure["w"][m][i]**2 - 4*w)**2)**(1/2))
            Ev = (error)/(1 + math.exp(-self.config["beta"]*sum))
            self.structure["v"][0][m] = self.structure["v"][0][m] - self.config["eta"]*Ev

if __name__ == "__main__":
    if (len(sys.argv) < 2):
        print("Warning: Command is not received.")
    else:
        start = time.time() * 100
        if sys.argv[1] == "test":
            path = "test.json"
            if ((len(sys.argv) > 2) and (sys.argv[2] != "-view")):
                path = sys.argv[2]
            network = NeuralNetwork()
            result = network.run(path)
            for i in range(len(result)):
                answer = ""
                if len(result[i]) > 2:
                    answer = " ["+str(result[i][2])+"]"
                view = ""
                if ((len(sys.argv) > 2) and (sys.argv[2] == "-view")) or ((len(sys.argv) > 3) and
(sys.argv[3] == "-view")):
                    view = " ("+str(result[i][0])+")"
                print("Test #" + str((i+1)) + answer + ": " + str(result[i][1]) + view)
            elif sys.argv[1] == "train":
                path = "train.json"
                if (len(sys.argv) > 2):
                    path = sys.argv[2]
                network = NeuralNetwork()
                network.train(path)
            else:
                print("Error: Command is wrong.")

```