

*А. П. Кушнір<sup>1</sup>, Б. Л. Копчак<sup>2</sup>, С. Я. Вовк<sup>1</sup>*<sup>1</sup>Львівський державний університет безпеки життєдіяльності, м. Львів, Україна<sup>2</sup>Національний університет "Львівська політехніка", м. Львів, УкраїнаORCID: <https://orcid.org/0000-0002-6946-8395> – А. П. Кушнір<http://orcid.org/0000-0002-2705-8240> – Б. Л. Копчак<https://orcid.org/0000-0001-5278-3754> – С. Я. Вовк

andrekushnir@ukr.net

## АПРОКСИМАЦІЯ ДИНАМІЧНИХ ХАРАКТЕРИСТИК ПОЖЕЖІ НЕЙРОННОЮ МЕРЕЖЕЮ ДЛЯ РОЗРОБКИ ІНТЕЛЕКТУАЛЬНИХ ПОЖЕЖНИХ СПОВІЩУВАЧІВ З СЕНСОРАМИ ДИМУ ТА ТЕПЛА

**Вступ.** На ранній стадії розвитку пожежі явища та продукти, що утворюються при горінні різних матеріалів, відрізняються, але є й загальні риси, як-от виділення тепла, утворення диму, випромінювання тощо. Ці поширені продукти горіння, які називають ознаками пожежі, також відомі як динамічні характеристики пожежі. Отже, характерними динамічними характеристиками пожежі є зміна: температури, концентрації диму та чадного газу, довжини хвилі інфрачервоного та ультрафіолетового випромінювання. Виявлення загорання передбачає контроль за цими параметрами пожежі, які є випадковими та невизначеними, та які важко охарактеризувати статистичними характеристиками. Ці динамічні характеристики використовують для дослідження та розроблення алгоритмів роботи пожежних сповіщувачів, які побудовані з використанням теорій нечіткої логіки, нейронних мереж на нечітких нейронних мереж.

**Мета і задачі дослідження.** Метою роботи є апроксимувати динамічні характеристики пожежі нейронною мережею, а саме: криві залежності середньооб'ємної температури в приміщенні від часу (температурні режими розвитку пожежі) та криві залежності задимлення на одиницю довжини від часу. Ці залежності необхідні для розробки та дослідження алгоритмів роботи інтелектуальних мультисенсорних пожежних сповіщувачів з сенсорами тепла і диму на основі нечіткої логіки та нейронних мереж.

**Основні результати дослідження.** Сьогодні найбільше з практичної точки зору використовуються мультисенсорні пожежні сповіщувачі з сенсорами тепла і диму, які аналізують зміну температури та задимленість. Тому в цій статті апроксимуємо динамічні характеристики пожежі. За допомогою комп'ютерного моделювання у програмному середовищі Fire Dynamics Simulator, яка працює на платформі інтерфейсу PyroSim змодельовано температурні режими пожежі та залежності задимлення на одиницю довжини від часу. Проведені дослідження науковцями доводять, що відносна похибка між змодельованими даними та експериментальними не перевищує 28%. Тому отримані криві можна використовувати для подальших досліджень. Апроксимовано отримані криві за допомогою нейронної мережі. Модель нейронної мережі була побудована та навчена в пакеті Neural Network Start GUI програмного середовища MATLAB 2020a. Після встановлення відсотків для формування даних для навчання, валідації (перевірки) та тестування вибрано архітектуру нейронної мережі. Для досягнення найкращого результату апроксимації залежностей кривих у цьому дослідженні кількість нейронів прихованого шару було визначено під час навчання нейронної мережі. Використання нелінійних функцій активації дозволяє налаштувати нейронну мережу на реалізацію нелінійних зв'язків між входом і виходом. Для навчання нейронної мережі використано три алгоритми навчання, а саме: Levenberg-Marquardt, Bayesian Regularization, Scaled Conjugate Gradient.

**Висновки.** В програмному середовищі Fire Dynamics Simulator змодельовано динамічні характеристики пожежі в приміщенні кабінету, адміністративному приміщенні і приміщенні виробництва фанери. Ці динамічні характеристики апроксимовано за допомогою нейронної мережі в пакеті Neural Network Start GUI програмного середовища MATLAB 2020a. В процесі навчання розробленої нейронної мережі дослідження показали, що значне збільшення кількості нейронів прихованого шару не приводить до покращення результатів, лише збільшує час навчання мережі. При кількості нейронів прихованого шару 15, 20 значення середньоквадратичної похибки і регресії майже однакові. Для апроксимації динамічних характеристик пожежі найкращий результат навчання нейронної мережі забезпечує алгоритм Bayesian Regularization. Тоді середньоквадратична помилка є найменшою. Як показують дослідження нейронна мережа відтворює ці криві з достатньою точністю. Так під час апроксимації кривої залежності середньооб'ємної температури від часу середньоквадратична похибка навчання дорівнює

278,599, а регресія – 0,9673. Під час апроксимації кривої залежності задимлення на одиницю довжини від часу середньоквадратична похибка навчання дорівнює 3,4714, а регресія – 0,9957. Апроксимовані криві динамічних характеристик пожежі нейронною мережею можуть використовуватися як вхідні дані при розробці та дослідженні алгоритмів роботи пожежних сповіщувачів з сенсорами тепла і диму на основі нечіткої логіки або нейронної мережі. Маючи ці апроксимовані криві можна навчити нейронну мережу пожежного сповіщувача розрізняти ознаки пожежі від оманливих явищ, не пов'язаних з пожежею.

**Ключові слова:** мультисенсорні пожежні сповіщувачі, динамічні характеристики пожежі, апроксимація, нейронна мережа, температурні режими пожеж.

*A. P. Kushnir<sup>1</sup>, B. L. Kopchak<sup>2</sup>, S. Ya. Vovk<sup>1</sup>*

<sup>1</sup>*Lviv State University of Life Safety, Lviv, Ukraine*

<sup>2</sup>*Lviv Polytechnic National University, Lviv, Ukraine*

## **APPROXIMATION OF FIRE DYNAMIC CHARACTERISTICS BY A NEURAL NETWORK FOR THE DEVELOPMENT OF INTELLIGENT FIRE DETECTORS WITH SMOKE AND HEAT SENSORS**

**Introduction.** At the early stage of fire development, the phenomena and products formed while the combustion of different materials is different. However, there are also common features such as heat generation, smoke generation, radiation generation, etc. These combustion products are called fire signs, also known as fire dynamic characteristics. Therefore, the characteristic fire dynamic characteristics are temperature change, smoke concentration change and carbon monoxide, and wavelength changes of infrared and ultraviolet radiation. Fire detection involves monitoring these fire parameters, which are random and uncertain and difficult to characterise due to statistical characteristics. These dynamic characteristics are used for research and development of algorithms for the operation of fire detectors, which are built using theories of fuzzy logic, and neural networks on fuzzy neural networks.

**Purpose.** The purpose of the paper is to approximate the fire dynamic characteristics by a neural network, namely, the dependence curves of the average volumetric temperature in the room on time (temperature regimes of fire development) and the dependence curves of smoke per unit length on time. These dependencies are necessary for the development and research of algorithms for the operation of intelligent multi-sensor fire detectors with heat and smoke sensors based on fuzzy logic and neural networks.

**Results.** Today, from a practical point of view, multi-sensor fire detectors with heat and smoke sensors, which analyse temperature changes and smoke are most commonly used. Therefore, this paper approximates the fire dynamic characteristics. With the help of computer simulation in the Fire Dynamics Simulator software, which works on the PyroSim interface platform, fire temperature regimes and the dependence of smoke per unit length on time are simulated. Research conducted by scientists proves that the relative error between simulated data and experimental data does not exceed 28%. Therefore, the resulting curves can be used for further research. The resulting curves are approximated using a neural network. The neural network model was built and trained in the Neural Network Start GUI package of the MATLAB 2020a software. After setting percentages, a neural network architecture is chosen to generate data for training, validation, and testing. To achieve the best result of the approximation of the dependences of the curves in this study, the number of neurons of the hidden layer was determined during the training of the neural network. The use of non-linear activation functions allows you to configure the neural network to implement non-linear connections between input and output. Three learning algorithms were used to train the neural network, namely: Levenberg-Marquardt, Bayesian Regularization, and Scaled Conjugate Gradient.

**Conclusions.** In the Fire Dynamics Simulator software, the fire dynamic characteristics in the office room, the administrative room and the plywood production premises are simulated. In the Neural Network Start GUI package of the MATLAB 2020a software, these dynamic characteristics are approximated using a neural network. In the process of training the developed neural network, studies have shown that a significant increase in the number of neurons of the hidden layer does not lead to improved results, but only increases the time of training the network. When the number of hidden layer neurons is 15, and 20, the mean square error and regression values are almost the same. To approximate the fire dynamic characteristics, the best result of neural network training is provided by the Bayesian Regularization algorithm. Then the root means the square error is the smallest. Research shows that the neural network reproduces these curves with sufficient accuracy. Thus, when approximating the curve of the dependence of the average volume temperature on time, the root means the square error of learning is 278.599, and the regression is 0.9673. Thus, when approximating the curve of the dependence of the average volume temperature on time, the root means the square error of training is 278.599, and the regression is 0.9673. When approximating the smoke per unit length versus the time curve, the root means the square error of training is 3.4714, and the regression is 0.9957. Approximated curves of the dynamic characteristics of a fire by a neural network can be used as input data in the development and research of algorithms for the operation of fire detectors with heat and smoke sensors based on fuzzy logic or a neural network. With these approximated curves, the neural network of the fire detector can be trained to distinguish the signs of fire from deceptive phenomena that are not related to fire.

**Keywords:** multi-sensor fire detectors, fire dynamic characteristics, approximation, neural network, temperature modes of fires.

**Постановка проблеми.** За останні три десятиліття значно зросла кількість пожеж у житлових та адміністративних будівлях. Згідно з дослідженнями Underwriters Laboratories (UL, Брук, Іллінойс, США), доступний час безпечної евакуації із житлових будинків під час пожежі з 1978 року зменшився з 17 до 3-4 хвилин [1]. Однією із причин те, що в сучасних будинках все більше використовуються меблі з синтетичних волокон. Цей матеріал горить при вищій температурі і набагато швидше, ніж натуральні матеріали. Підвищення чутливості димових пожежних сповіщувачів (ПС), які широко використовуються в житлових та офісних приміщеннях, є одним із потенційних способів вирішення цієї проблеми. Однак підвищення їхньої чутливості призводить до збільшення частоти помилкових спрацювань. Статистичні дані Національної асоціації протипожежного захисту показують, що значна кількість димових ПС спрацьовують через різні оманливі явища, які не пов'язані з пожежами. У Великобританії помилкові спрацювання систем пожежної сигналізації (СПС) з димовими ПС коштують підприємствам і пожежно-рятувальним службам понад 1 мільярд фунтів стерлінгів щороку [2]. Це є результатом того, що більшість димових ПС не можуть розрізняти частки диму, які утворюються під час пожежі, та частинок, які не пов'язані з пожежею.

На ранній стадії розвитку пожежі явища та продукти, що утворюються при горінні різних матеріалів, відрізняються, але є й загальні риси, як-от виділення тепла, утворення диму, випромінювання тощо. Ці поширені явища та продукти горіння (температура, вологість, дим, CO<sub>2</sub>, CO тощо) називаються ознаками пожежі, також відомі, як параметри пожежі або динамічні характеристики пожежі [3, 4]. Отже, характерними динамічними характеристиками пожежі є зміна температури, концентрації диму та чадного газу, довжини хвилі інфрачервоного та ультрафіолетового випромінювання. Виявлення загорання передбачає контроль за цими параметрами пожежі, які є випадковими та невизначеними, та які важко охарактеризувати через статистичні характеристики. Дослідження їх динамічних характеристик використовують для розробок алгоритмів роботи ПС, які здатні розрізняти ознаки пожежі від оманливих явищ, не пов'язаних з пожежею (від впливу навколишнього середовища). Для раннього виявлення пожежі сьогодні пропонуються алгоритми роботи ПС, побудовані на основі аналізу та об'єднання даних, отриманих із декількох сенсорів (давачів) та з використанням

теорій нечіткої логіки, нейронних мереж на нечітких нейронних мереж (нейрон-фаззі мережі).

**Аналіз останніх досягнень і публікацій.** Різні матеріали під час горіння в різних середовищах утворюють різні продукти горіння. Отже, при виявленні загорання за однією ознакою пожежі виникнуть проблеми непродуманого судження та дезінформації. Мультисенсорні ПС, які отримують і аналізують інформацію від декількох сенсорів швидше виявляють загорання та забезпечують більшу надійність системи з меншою кількістю помилкових спрацювань, порівняно з ПС, який має лише один сенсор. Вони мають можливість перехресної перевірки даних, отриманих від різних сенсорів. Дослідження з виявлення пожеж з використанням методів об'єднання та аналізу даних, отриманих із декількох сенсорів, розділяють на три типи підходів. Перший тип базується на умовній ймовірності, статистиці та нечітких висновках. Наприклад, в роботі [5] побудована СПС на основі Байєсівської мережі. Розглянуто внутрішню логіку взаємозв'язку між СПС та фізико-хімічними характеристиками, що утворюються в процесі горіння за допомогою аналізу пожежі. Фільтр Калмана може об'єднувати різноманітні дані про пожежу та ефективно видаляти шум [6]. Використання нечіткої логіки для виявлення загорання спрощує об'єднання даних, отриманих від кількох сенсорів, що полегшує їх аналіз. Нечітка логіка також найкраще наближає фактичні значення різних контрольованих ознак пожежі для точного та ефективного виявлення загорання [7-8]. Щоб побудувати ПС на основі нечіткої логіки, необхідно знати, як змінюються ознаки пожежі у часі залежно від типу пожежі, тобто необхідно мати набутий досвід, щоб формувати функції належності та базу правил. Другий тип – це метод штучного інтелекту (нейронні мережі). Система використовує алгоритми, які об'єднують багато інформації, щоб реалізувати людський досвід і працюють з нечіткою інформацією. У поєднанні з функціями самонавчання та самонастроювання нейронної мережі будуються інтелектуальні ПС. Третій тип поєднує переваги двох попередніх типів і використовує нечітку нейронну мережу для об'єднання даних, отриманих від декількох сенсорів, та прийняття рішення. Розподілене представлення знань зазвичай унеможливило приведення коректного пояснення структури нейронної мережі зрозумілими людині поняттями, такими як лінгвістичні вирази “якщо-тоді”. Таким чином, нейронні мережі наділені можливостями навчання, проте не забезпечують чіткої схеми представлення знань, в

той час як у нечітких системах ситуація є цілком протилежною. Поєднання згаданих підходів у нечіткій нейронній мережі дозволило компенсувати недоліки кожного з них.

У роботі [10] пропонується модель нейронної мережі з прогнозуванням відхилень, яка об'єднує дані з 6 сенсорів: трьох сенсорів газу, сенсорів температури і вологості, тепла і диму. Результати показують, що дана модель має високу швидкість та точність. Час виконання становить 0,0132 секунди. Крім того, модель зменшує частоту помилкових спрацювань. Мультисенсорна інформаційна система виявлення загорання на основі об'єднання даних запропонована в [11]. Вона також використовує нейронну мережу зворотного поширення для об'єднання даних з датчиків температури, густини диму та CO. Результати показують, що система має кращу продуктивність у реальному часі, забезпечуючи точність виявлення пожежі. В роботі [12] розроблено алгоритм розпізнавання загорання інтелектуальної СПС на основі нейронної мережі. Система використовує багатоканальну технологію, щоб об'єднати отриману інформацію з декількох сенсорів, а саме: сенсора температури, фотоелектричного сенсора диму та інфрачервоного сенсора. Для точного прогнозування рівня пожежі було використано інформаційний синтез та навчання нейронної мережі методом зворотного поширення, що підвищує надійність пожежної сигналізації та знижує частоту помилкових тривог. Однак в роботах [10-12] для навчання нейронної мережі, як приклад, бралися лише деякі вхідні значення сигналів, які відповідають пожежі.

В роботах [13, 3] розроблені методи нейронної мережі для виявлення пожежі, які ґрунтуються на аналізі зміни трьох репрезентативних параметрів пожежі: температури, густини диму та концентрації CO. Результати дослідження показують, що алгоритми виявлення загорання, запропоновані в цих роботах, є ефективнішими, ніж традиційні алгоритми. В роботі [13] результати випробувань показують, що коефіцієнт помилок ідентифікації для пожежі, тління та відсутності пожежі становить менше 5%, що значно знижує частоту помилкових спрацювань. Ця нейронна мережа покращує здатність адаптуватися до навколишнього середовища та точно передбачати пожежі. Однак в роботі [13] для навчання нейронної мережі використовували лише числові значення з восьми комбінацій. Як стверджують автори в роботі [3], отримані та проаналізовані дані на ранній стадії розвитку пожежі, мають більший вплив на продуктивність алгоритму

раннього виявлення загорання, ніж аналіз даних на всьому проміжку розвитку пожежі. Щоб підвищити продуктивність алгоритмів, ці дані з великою частотою вимірюються, щоб вихід нейронної мережі зворотного поширення більш точно відповідав цим вибіркам періоду. Значення цих даних були використані як вхідні дані для навчання нейронної мережі зворотного поширення. Тому навчальний набір включав лише дані зростаючої фази горіння, щоб забезпечити монотонність даних. Алгоритм може правильно розпізнати шість тестових пожеж, відповідно до стандартів EN54, і скоротити час виявлення пожежі на 32%.

Отже, нейронна мережа використовується в алгоритмах роботи ПС для виявлення загорання на основі об'єднання і обробки вхідної інформації, отриманої від різних сенсорів. Для того щоб вона ефективно виявляла загорання на ранній стадії розвитку пожежі, її треба навчити на ці вхідні дані. Для цього ми повинні мати дані динамічних характеристик пожежі, які реально відображають саму пожежу.

Однією з перших аналітичних моделей пожежі була модель, що відображає залежність температури "стандартної" пожежі від часу. Її, зазвичай, називають стандартною розрахунковою кривою "температура-час". За нормами стандартний температурний режим пожежі математично записують у вигляді [14, 15]:

$$\Theta_g(t) = 345 \lg(8t + 1) + 20,$$

де  $\Theta_g$  – температура газу в печі, °C;  $t$  – тривалість теплового впливу протягом вогневого випробування, хв.

Стандартний температурний режим відображає умовну модель пожежі. Крива температура-час є лише спрощеним представленням термічної дії пожежі. Вона відображає збільшення температури всередині розглядуваного відсіку, навіть після того, коли всі горючі матеріали знищені. Ця крива використовується при випробуваннях у вогневих печах.

В роботі [16] автор в результаті аналізу сучасного стану теоретичних та практичних досліджень пожеж показує, що розрахункові режими реальної пожежі мають суттєво нижчі температури за стандартний температурний режим і різниця може становити від 400 до 800 °C. Це пояснюється врахуванням типу пожежного навантаження, геометрії його розташування, геометрії та положення прорізів, наявної вентиляції, наявної системи автоматичного пожежогасіння. Були проведені пожежні випробування на повномасштабних та зменшених моделях приміщень, у результаті

яких були отримані дані протемпературні прорізів ( $O$ ) та щільності пожежного режиму розвитку пожеж з врахуванням коефіцієнта, навантаження ( $q_{t,d}$ ).

Максимальна середньооб'ємна температури пожежі дорівнює:

$$\Theta_{e\max} = k_{m\theta} \cdot k_{\theta} \cdot (384.587 + 17281.1 \cdot O + 0.218 \cdot q_{t,d} + 1.196 \cdot O \cdot q_{t,d}),$$

де:  $k_{m\theta}$ ,  $k_{\theta}$  – коефіцієнти для визначення параметрів пожежі.

Час досягнення максимальної середньооб'ємної температури:

$$t_m = k_{mt} \cdot k_{\theta t} \cdot (101.211 + 1947.368 \cdot O + 0.1933 \cdot q_{t,d} + 3.1898 \cdot O \cdot q_{t,d}),$$

де:  $k_{mt}$ ,  $k_{\theta t}$  – коефіцієнти для визначення параметрів пожежі.

Тривалість пожежі:

$$\tau_m = k_{m\tau} \cdot k_{\theta\tau} \cdot (33.576 + 160.287 \cdot O + 2.552 \cdot q_{t,d} + 0.236 \cdot O \cdot q_{t,d}),$$

де:  $k_{m\tau}$ ,  $k_{\theta\tau}$  – коефіцієнти для визначення параметрів пожежі.

Розроблена математична модель температурних режимів розвитку пожеж порівнювалася з результатами моделювання повномасштабних випробувань та з результатами комп'ютерного моделювання у програмному середовищі Fire Dynamics Simulator (FDS), розробленому Інститутом стандартизації Сполучених Штатів Америки. Результати досліджень показали, що відносна похибка, визначена при порівнянні експериментальних та розрахункових даних, не перевищує 28%, а середньоквадратичне відхилення не перевищує 51 °C [16]. Це означає, що математичні моделі, реалізовані у програмному середовищі FDS, достатньо точно відображають температурні режими розвитку пожеж в приміщеннях, а отже їх можна використовувати для аналізу.

В статті [17] для аналізу значення величини температури у будинку складена теплова модель будинку. Модель описує теплові характеристики будинку, в якому планується встановити ПС, враховує його систему опалення та температуру повітря зовнішнього середовища. Ця модель також враховує геометрію будинку, теплові властивості будівельних матеріалів, тепловий опір будинку, характеристики нагрівача та початкову кімнатну температуру. Тепловий потік нагрівача в кімнаті визначається як:

$$\frac{dQ}{dt} = (T_h - T_r) M \dot{C},$$

де:  $dQ/dt$  – тепловий потік від нагрівача;  $C$  – теплоємність повітря при постійному тиску;  $M \dot{C}$  – масова витрата повітря через нагрівач (кг/год.);  $T_h$  – температура гарячого повітря від нагрівача;  $T_r$  – поточна температура повітря в приміщенні.

Поточна температура повітря в приміщенні може бути виражена як:

$$\frac{dQ_l}{dt} = \frac{T_r - T_0}{R_{eq}},$$

$$\frac{dT_r}{dt} = \frac{1}{M_{air} C} \left( \frac{dQ_h}{dt} - \frac{dQ_l}{dt} \right),$$

де:  $M_{air}$  – це маса повітря всередині будинку, а  $R_{eq}$  – еквівалентний тепловий опір будинку.

При розробці алгоритму роботи ПС з сенсорами тепла і диму необхідно враховувати, не лише як змінюється температура в приміщенні, але й як змінюється задимленість. Оптична густина диму може бути більша від допустимого значення ( $\mu \leq 1,2$  Нп/м, що забезпечує видимість до 2 м, тобто в межах росту людини, яка при переміщенні повинна бачити підлогу). В роботах [18, 19] наведено залежність оптичної густини диму в приміщенні:

$$\mu(\tau) = \frac{c_p \rho_0 T_0 D}{Q_{\min} \eta (1 - \varphi)} \left[ 1 - \exp \left( - \frac{\psi_n S_n(\tau) \eta Q_{\min} (1 - \varphi)}{c_p \rho_0 T_0 V} \tau \right) \right],$$

де:  $c_p$  – ізобарна теплоємність газового середовища;  $\eta$  – коефіцієнт повноти згоряння;  $\varphi$  – коефіцієнт тепловтрат;  $S_n$  – площа пожежі;  $Q_{\min}$  – найнижча теплота згоряння;  $\psi_n$  – питома швидкість вигорання;  $D$  – димоутворююча здатність речовин, які розташовані в приміщенні і горять при пожежі, внутрішній об'єм приміщення;  $\tau$  – тривалість димовиділення.

Результати розрахунків показують, що оптична густина диму при пожежі, наприклад, для адміністративних приміщень, досягає свого приблизного максимуму на 5-й хвилині вільного горіння [18], для кімнати – приблизно на 6,5 хв, для приміщення опоряджувально-складального деревообробного цеху – приблизно на 7,7 хв [19], а далі іде на спад.

Програмне середовище FDS також дозволяє достатньо точно розрахувати затемнення від диму

(задимлення) на одиницю довжини, тобто визначити поширення диму в приміщенні.

**Мета і задачі дослідження.** Метою роботи є апроксимувати динамічні характеристики пожежі нейронною мережею, а саме: криві залежності середньооб'ємної температури в приміщенні від часу та криві залежності задимлення на одиницю довжини в приміщенні від часу. Ці залежності необхідні для розробки та дослідження алгоритмів роботи інтелектуальних пожежних сповіщувачів з сенсорами тепла і диму на основі нечіткої логіки та нейронних мереж.

Для досягнення поставленої мети потрібно виконати такі завдання:

- в програмному середовищі FDS змодельовати криві залежності середньооб'ємної температури від часу (криві температурних режимів розвитку пожежі) для різних приміщень;
- в програмному середовищі FDS змодельовати криві залежності задимлення на одиницю довжини від часу (поширення диму в приміщенні) для різних приміщень;
- в пакеті Neural Network Start GUI програмного середовища MATLAB побудувати модель нейронної мережі для апроксимації змодельованих динамічних характеристик пожежі;
- навчити нейронну мережу.

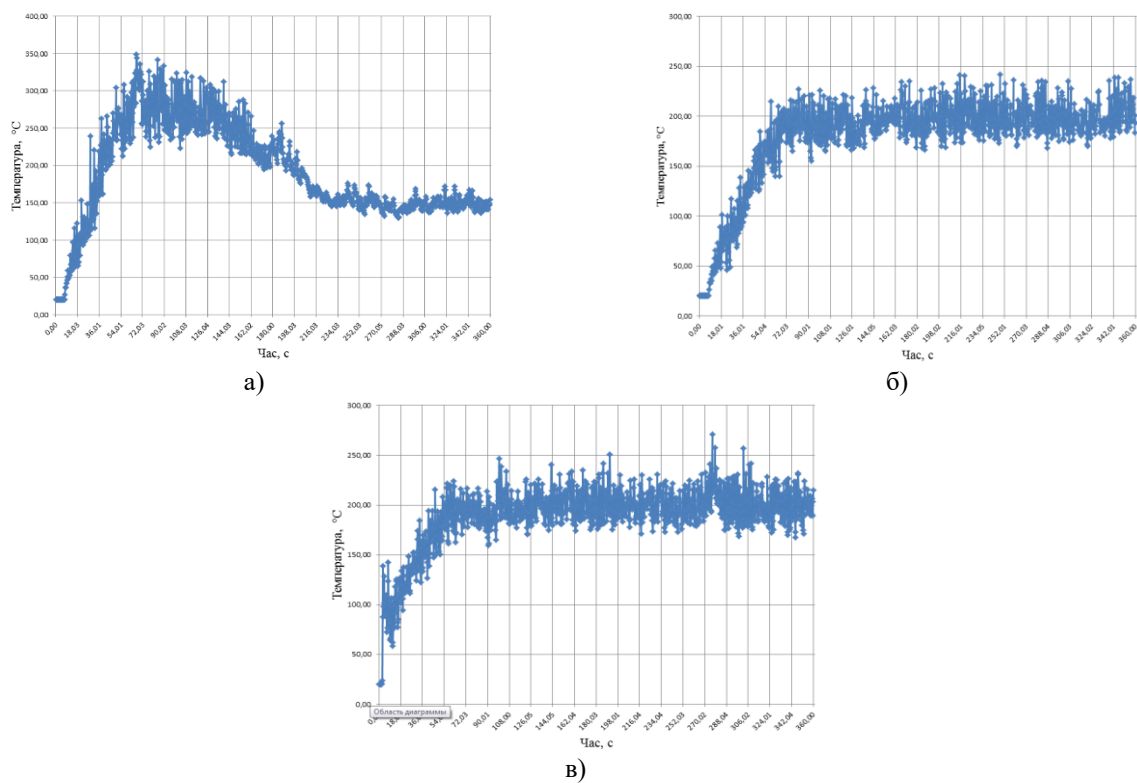
**Результати роботи.** Підвищити ефективність виявлення пожежі на ранній стадії її розвитку СПС можна за завдяки розробленню ефективних алгоритмів роботи ПС на основі нечіткої логіки або нейронних мереж. Для цього необхідно знати як під час пожежі, а особливо на ранній стадії її розвитку, змінюються вхідні дані: температура, оптична густина диму (концентрація диму), загазованість тощо. Відповідно, як було зазначено вище, маючи ці вхідні дані динамічних характеристик пожежі, на основі нейронної мережі та об'єднання інформації з декількох сенсорів, можна побудувати ефективний алгоритм роботи ПС. Завдяки цьому чутливість виявлення пожежі ПС може бути ефективно покращена, а частота помилкових спрацювань ПС – зменшена.

Сьогодні найбільшого поширення у світі набули мультисенсорні ПС з сенсорами тепла і диму, які аналізують зміну температури та задимленість. Тому в цьому дослідженні будемо апроксимувати динамічні характеристики пожежі, а саме, криві залежності середньооб'ємної температури в приміщенні та криві залежності задимлення на одиницю довжини (оптичної густини диму) від часу.


Порогові теплові ПС спрацювають на порогове значення температури, наприклад, мінімальна статична температура спрацювання ПС класу А1 і А2 54 °С, згідно з ДСТУ EN 54-

5:2019 [20]. Максимально-диференційні ПС спрацювають як на порогове значення температури, так і на швидкість зміни температури, наприклад, 9°С/хв. Мінімальне значення порога спрацювання димового ПС має бути не меншим за 0,05 дБ/м, згідно з ДСТУ EN 54-7:2019 [21]. Згідно із стандартом UL217 [22], спрацювання сенсора диму має відбутись протягом 2 хвилин при перевищенні оптичної густини диму 1,6 %/м. Крім того, спрацювання димового ПС має відбуватись при ослабленні пропускання світла димом: для сірого диму – не раніше за 1,6 %/м і не вище за 12,5 %/м; для чорного диму – не раніше за 1,6 %/м і не вище за 36,71 %/м. Мультисенсорні ПС з сенсорами тепла та димову повинні відповідати європейському стандарту BS EN 54-29:2015 [23]. В цих стандартах описано методи контролю технічного стану ПС, що проводиться шляхом випробувань. Слід зазначити, що стандарти [22] і [23] поки що в Україні не прийняті, комбіновані тепло-димові ПС мають відповідати вимогам ДСТУ EN 54-5:2019 [20] та ДСТУ EN 54-7:2019 [21].

Як уже зазначалося, в роботі [16] автор доводить, що температурні режими пожежі, отримані за допомогою проведення експериментальних досліджень у триповерховій будівлі та за допомогою комп'ютерного моделювання у програмному середовищі FDS, збігаються з достатньою точністю. Відносна похибка не перевищує 28% [16]. Тому, в програмному середовищі FDS змодельовано, як змінюється температура і оптична густина диму під час пожежі залежно від часу для різних приміщень. Програма FDS працює на платформі інтерфейсу PyroSim. FDS – це польова модель, за допомогою якої можна моделювати поширення диму, температури, чадного газу та інших небезпечних факторів під час пожежі. В програмному середовищі FDS можна задавати різні приміщення з різним пожежним навантаженням. З бази даних виберемо три приміщення: приміщення кабінету, адміністративне приміщення і виробниче деревообробне приміщення (приміщення виробництва фанери). Оскільки, згідно з ДБН В.2.5-56:2014 [24], максимальна відстань між тепловими ПС повинна бути не більше 7 м та ПС і стіною не більше 3,5 м, тому задаємо розмір усіх трьох приміщень – 7×7 м і висоту приміщення – 3 м. На рис. 1 показано результати моделювання температурних режимів пожежі. На рис. 2 показано залежності задимлення (затемнення) на одиницю довжини від часу (поширення диму в приміщенні).



**Рисунок 1** – Температурні режими пожежі: а) приміщення кабінету, б) адміністративне приміщення, в) приміщення виробництва фанери



**Рисунок 2** – Криві задимлення на одиницю довжини від часу: а) приміщення кабінету, б) адміністративне приміщення, в) приміщення виробництва фанери

Для моделювання нейронних мереж в програмному середовищі MATLAB було розроблено пакет Neural Network Start GUI, який служить

засобом, що допомагає користувачам розвивати методи проектування і розширювати область застосування нейронних мереж. Цей графічний інтерфейс дозволяє, не звертаючись до командного

вікна системи MATLAB, створювати, навчати, моделювати, а також імпортувати або експортувати нейронні мережі і дані, використовуючи тільки інструментальні можливості GUI-інтерфейсу.

З метою подальшої розробки алгоритму роботи інтелектуального тепло-димового ПС, апроксимуємо отримані криві (рис. 1, рис. 2) за допомогою нейронної мережі. Модель нейронної мережі була побудована та навчена в програмному середовищі MATLAB

2020а. Структура нейронної мережі, яка застосовується для апроксимації залежностей кривих температурних режимів та поширення диму в приміщенні показана на рис. 3. Вхідними даними є значення часу, авихідними даними є в першому випадку значення температури в місці встановлення ПС, а в другому випадку – значення затемненості на одиницю довжини.

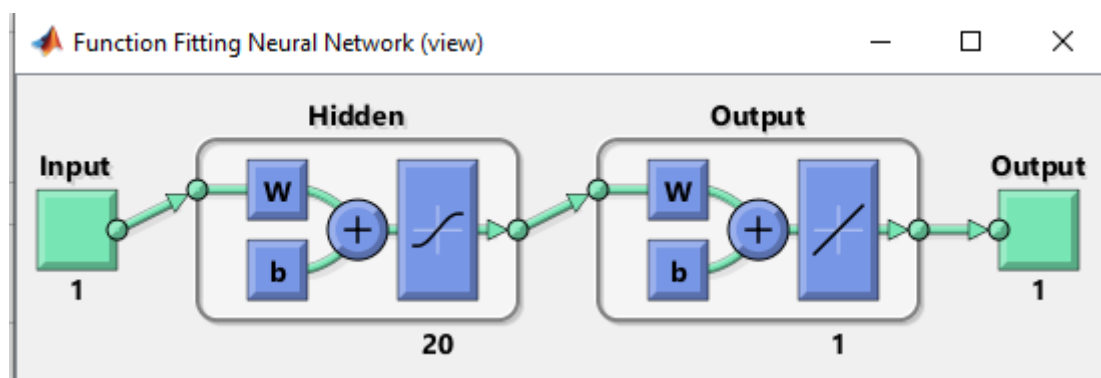


Рисунок 3 – Структура нейронної мережі

Нейронну мережу, яка забезпечує найменші похибки після навчання легше отримати шляхом підбору кількості нейронів прихованого шару, а не кількості прихованих шарів. На рис. 3 показана двошарова мережа прямого зв'язку з прихованими сигмоподібними нейронами та лінійними вихідними нейронами (fitnet). Вона добре відповідає проблемам багатовимірного відображення, якщо врахувати узгоджені дані та достатню кількість нейронів у своєму прихованому шарі.

Вагові коефіцієнти та зміщення між шарами нейронної мережі були отримані шляхом навчання в інтервалах навчального набору. 1001 набір даних про пожежу були випадковим чином розділені на три підмножини (види зразків): навчальні, валідаційні (перевірка) та тестові набори. Для навчання моделі використовується навчальний набір і мережа коригується відповідно до її похибки. Валідація використовується для вимірювання результатів мережі та для припинення навчання, коли результат перестає покращуватися. Тестовий набір не впливає на навчання, тому використовується (забезпечується) незалежно вимірювання оцінки продуктивності мережі під час і після навчання. Співвідношення наборів для навчання, валідації та тестування становили 90%, 5% та 5%.

Після встановлення відсотків для формування даних для навчання та тестування вибираємо архітектуру нейромережі (fitnet). Архітектура мережі складається з опису того, скільки шарів має мережа, кількості нейронів у

кожнім шарі, виду функції активації кожного шару й інформації про з'єднання шарів.

Однією з труднощів використання нейронної мережі є те, що не існує теоретичної формули для визначення кількості нейронів прихованого шару. Однак їх вибір пов'язаний з нормальною роботою всієї мережі. Зазвичай дослідники виводять інтервал для кількості вузлів у прихованому шарі на основі деяких емпіричних формул, а потім вибирають методом моделювання відповідні вузли в межах інтервалу. Більша кількість нейронів у прихованих шарах забезпечує більшу продуктивність мережі. Однак збільшення кількості нейронів у прихованих шарах збільшує час навчання і подальше збільшення їх кількості не покращує її продуктивність.

Для досягнення найкращого результату апроксимації залежностей у цьому дослідженні кількість нейронів прихованого шару було визначено під час навчання нейронної мережі. Використання нелінійних функцій активації дозволяє налаштувати нейронну мережу на реалізацію нелінійних зв'язків між входом і виходом.

Навчання нейронної мережі здійснюємо шляхом закладених алгоритмів навчання в пакет Neural Network Start GUI. Навчити нейронну мережу – значить отримати від неї таку поведінку, яку ми від неї вимагаємо. Алгоритм навчання – це набір формул, що дозволяє за значенням похибки обчислити необхідні значення корекції для вагових коефіцієнтів мережі. Процес повторюється доти, доки вся навчальна вибірка не



буде відтворена з заданою точністю. Такий процес називають «навчанням з учителем».

Для навчання нейронної мережі будемо використовувати три алгоритми навчання, які закладені в пакеті Neural Network Start GUI. Це алгоритми навчання: Levenberg-Marquardt (Левенберга-Марквардта), Bayesian Regularization (Байєсова регуляція), Scaled Conjugate Gradient (масштабований спряжений градієнт). В процесі навчання визначимо, який з них забезпечує кращий результат.

Алгоритм навчання Левенберга-Марквардта (trainlm) потребує більше пам'яті, але менше часу. Навчання автоматично припиняється, коли узагальнення перестає покращуватися, на що вказує збільшення середньоквадратичної похибки вибірок перевірки. Алгоритм навчання Bayesian Regularization зазвичай потребує більше часу, але може забезпечити хороший результат для складних, малих або шумних наборів даних. Навчання припиняються відповідно до адаптивної мінімізації ваги (регуляризації). Алгоритм навчання Scaled Conjugate Gradient

потребує менше пам'яті. Навчання автоматично припиняється, коли результат перестає покращуватися, на що вказує збільшення середньоквадратичної похибки вибірок перевірки.

Для оцінки продуктивності використаних алгоритмів під час апроксимації кривих в цьому дослідженні були використані деякі показники ефективності і точності алгоритмів, а саме, середньоквадратична похибка (MSE) і регресія (R). Чим менше значення MSE, тим вища точність нейронної мережі. Це показує, що нейронна мережа відповідає вимогам високої точності. В процесі навчання нейронної мережі досліджували, як кількість нейронів прихованого шару та різні алгоритми навчання впливають на її продуктивність. У табл. 1 наведено результати навчання нейронної мережі для апроксимації функції залежності середньооб'ємної температури від часу, а у табл. 2 – результати навчання нейронної мережі для апроксимації функції залежності задимлення на одиницю довжини від часу.

**Таблиця 1**

Результати навчання нейронної мережі для апроксимації функції залежності середньооб'ємної температури від часу

Кількість прихованих нейронів	Результати							
		Levenberg-Marquardt			Bayesian Regularization		Scaled Conjugate Gradient	
		Samples	MSE	R	MSE	R	MSE	R
10	Training	901	308,099	0,9632	314,554	0,9631	350,390	0,9603
	Validation	50	331,669	0,9815	0	0	288,099	0,9356
	Testing	50	288,677	0,9629	283,798	0,9609	337,355	0,9786
15	Training	901	291,989	0,9658	287,793	0,9663	342,972	0,9591
	Validation	50	245,393	0,9749	0	0	237,043	0,9610
	Testing	50	260,598	0,9623	228,263	0,9692	489,877	0,9592
20	Training	901	288,345	0,9660	278,599	0,9673	328,246	0,9625
	Validation	50	337,903	0,9753	0	0	222,4401	0,9665
	Testing	50	248,355	0,9622	250,052	0,9663	253,578	0,9550

**Таблиця 2**

Результати навчання нейронної мережі для апроксимації функції залежності задимлення на одиницю довжини від часу

Кількість прихованих нейронів	Результати							
		Levenberg-Marquardt			Bayesian Regularization		Scaled Conjugate Gradient	
		Samples	MSE	R	MSE	R	MSE	R
10	Training	901	4,3118	0,9946	3,6957	0,9951	6,9603	0,9914
	Validation	50	4,05174	0,9928	0	0	3,1583	0,9959
	Testing	50	4,4016	0,9952	3,3972	0,9972	8,4043	0,9824
15	Training	901	3,8352	0,9949	3,6323	0,9952	5,2211	0,9936
	Validation	50	3,0096	0,9979	0	0	4,3620	0,9806
	Testing	50	3,6903	0,9943	2,3181	0,9980	8,9133	0,9886
20	Training	901	3,7084	0,9953	3,4714	0,9957	4,3161	0,9946
	Validation	50	2,5299	0,9935	0	0	1,7169	0,9967
	Testing	50	3,2011	0,9972	2,9423	0,9941	3,1701	0,9967

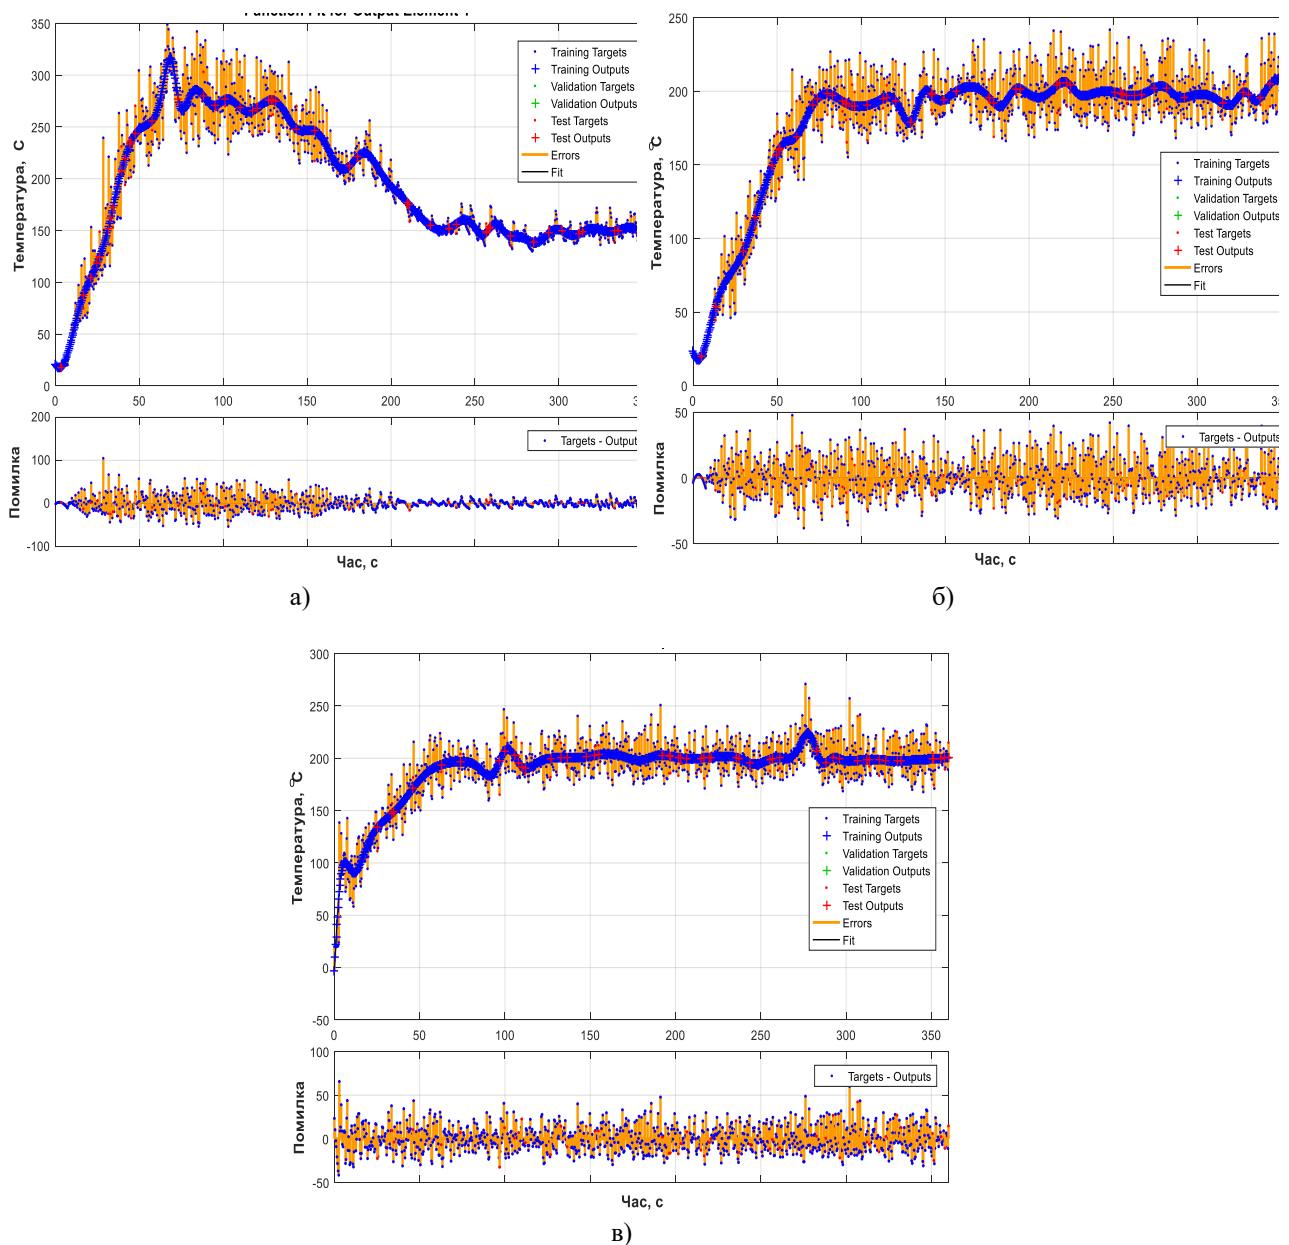
Як видно з таблиць, збільшення кількості нейронів прихованого шару покращує результати

навчання нейронної мережі. Однак слід зазначити, що при кількості нейронів прихованого шару 15, 20


результати MSE та R майже однакові. Крім того, при певній кількості навчання результати MSE та R отримані при кількості нейронів прихованого шару 15 можуть бути аналогічними, як при 20 нейронів. З таблиць видно, що найкращий результат навчання нейронної мережі (нейронна мережа досягає відмінного рівня точності) забезпечує алгоритм навчання Bayesian Regularization. Нейронна мережа, навчена алгоритмом Bayesian Regularization, має найменшу середньоквадратичну похибку, коли кількість нейронів прихованого шару дорівнює 20. Під час апроксимації кривої залежності

температури від часу середньоквадратична похибка навчання  $MSE = 278,599$ , а  $R = 0,9673$ ; валідація  $MSE = 0$ ,  $R = 0$ ; тест  $MSE = 250,052$ ,  $R = 0$ . Під час апроксимації функції залежності задимлення на одиницю довжини від часу навчання  $MSE = 3,4714$ ,  $R = 0,9957$ ; валідація  $MSE = 0$ ,  $R = 0$ ; тест  $MSE = 2,9423$ ,  $R = 0,9941$ .

На рис. 4 показано результати апроксимації кривих температурних режимів пожежі змодельованою нейронною мережею, а на рис. 5 результати апроксимації кривих залежності задимлення на одиницю довжини від часу.




**Рисунок 4** – Результати апроксимації кривих температурних режимів пожежі змодельованою нейронною мережею: а) приміщення кабінету, б) адміністративне приміщення, в) приміщення виробництва фанери



а)

б)



в)

**Рисунок 5** – Результати апроксимації кривих задимлення на одиницю довжини від часу змодельованою нейронною мережею: а) приміщення кабінету, б) адміністративне приміщення, в) приміщення виробництва фанери

Як видно з рис. 4 і рис. 5 нейронна мережа відтворює криві температурних режимів та задимлення на одиницю довжини від часу. Отримані значення цих даних на ранній стадії розвитку пожежі є ключовими для розроблення ефективних алгоритмів роботи ПС на основі нейронної мережі, а отже, для виявлення загорання. Маючи ці вхідні дані динамічних характеристик пожежі, можна навчити нейронну мережу ПС. Завдяки цьому чутливість виявлення пожежі ПС може бути покращена, а частота помилкових спрацювань – зменшена.

Апроксимовані криві будуть використані як вхідні сигнали при дослідженні розроблених алгоритмів розпізнавання загорання, які використовують об'єднання та аналіз даних із

різних сенсорів на основі нечіткої логіки або нейронної мережі.

### Висновки

1. В програмному середовищі FDS змодельовано динамічні характеристики пожежі, а саме, криві залежності середньооб'ємної температури в приміщенні від часу (температурні режими розвитку пожеж) та криві залежності задимлення на одиницю довжини від часу при пожежі в приміщеннях: приміщення кабінету, адміністративне приміщення і приміщення виробництва фанери.

2. В процесі навчання розробленої нейронної мережі, в пакеті Neural Network Start GUI програмного середовища MATLAB, для апроксимації динамічних характеристик пожежі, дослідження показали, що збільшення кількості

нейронів прихованого шару покращує результати навчання нейронної мережі. Однак слід зазначити, що при кількості нейронів прихованого шару 15, 20 значення середньоквадратичної похибки та регресії майже однакові. Значне збільшення кількості нейронів прихованого шару не приводить до покращення результатів, лише збільшує час навчання мережі.

3. В процесі навчання розробленої нейронної мережі, для апроксимації динамічних характеристик пожежі, дослідження показали, що найкращий результат навчання нейронної мережі забезпечує алгоритм навчання Bayesian Regularization. Він забезпечує хороші результати для складних, малих або шумних наборів даних. Нейронна мережа, навчена алгоритмом Bayesian Regularization, має найменшу середньоквадратичну похибку.

4. Як показали результати дослідження, нейронна мережа відтворює динамічні характеристики пожежі з достатньою точністю. Під час апроксимації кривої залежності середньооб'ємної температури від часу середньоквадратична похибка навчання дорівнює 278,599, а регресія – 0,9673. Під час апроксимації кривої залежності задимлення на одиницю довжини від часу середньоквадратична похибка навчання дорівнює 3,4714, а регресія – 0,9957.

5. Апроксимовані криві динамічних характеристик пожежі нейронною мережею будуть використані, як вхідні сигнали при дослідженні розроблених алгоритмів роботи ПС з сенсорами тепла і диму на основі нечіткої логіки або нейронної мережі.

#### Список літератури:

1. Roman, J. Smoke Signals. In NFPA Journal; National Fire Protection Association: Quincy, MA, USA, 2018.
2. Chagger, R.; Smith, D. The Causes of False Fire Alarms in Buildings; Briefing Paper; BRE Global Limited: Watford, UK, 2014. 31 p.
3. Lesong Wu, Lan Chen, and Xiaoran Hao. Multi-Sensor Data Fusion Algorithm for Indoor Fire Early Warning Based on BP Neural Network. MDPI, Information 2021, Vol. 12, Issue 12(2), 59. URL: <https://doi.org/10.3390/info12020059>.
4. Yang Feng, Qu Na, and Li Chao. Compound Fire Detection Algorithm Based on Fuzzy Neural Network. Proceedings of the 2017 2nd International Conference on Machinery, Electronics and Control Simulation (MECS 2017), Taiyuan, China, 24-25 June, 2017. URL: <https://doi.org/10.2991/mecs-17.2017.133>.
5. Jing, C. and Jingqi, Fu. Fire Alarm System Based on Multi-Sensor Bayes Network. 2012 International Workshop on Information and Electronics Engineering. Procedia Engineering. 2012, vol. 29,

pp. 2551–2555. URL: <https://doi.org/10.1016/j.proeng.2012.01.349>.

6. Wang, T., Hu, J., Ma, T. and Song, J. Forest fire detection system based on Fuzzy Kalman filter. In Proceedings of the 2020 International Conference on Urban Engineering and Management Science (ICUEMS), Zhuhai, China, 24–26 April 2020, pp. 630–633. DOI: 10.1109/ICUEMS50872.2020.00138.

7. Andrii Kushnir, and Bohdan Kopchak. Development of Intelligent Point Multi-Sensor Fire Detector with Fuzzy Correction Block. 2019 IEEE XVth International Conference on the Perspective Technologies and Methods in MEMS Design (MEMSTECH), Polyana, Ukraine, 22-26 May 2019, pp. 41-45. DOI: 10.1109/MEMSTECH.2019.8817395.

8. Andrii Kushnir, and Bohdan Kopchak. Development of Multiband Flame Detector with Fuzzy Correction Block. 2021 IEEE XVII International Conference on the Perspective Technologies and Methods in MEMS Design (MEMSTECH), Polyana, Ukraine, 12-16 May 2021, pp. 58-63. DOI:10.1109/MEMSTECH.2019.8817395.

9. Uduak Umoh, Udoinyang G. Inyang, and Emmanuel E. Nyoho. Interval Type-2 Fuzzy Logic for Fire Outbreak Detection. International Journal on Soft Computing, Artificial Intelligence and Applications (IJSCAI), August 2019, Vol.8, No.3, pp. 27–46. DOI:10.5121/ijscai.2019.8303.

10. Mert Nakip, and Cüneyt Güzeliş. Multi-Sensor Fire Detector based on Trend Predictive Neural Network. In Proceedings of 2019 11th International Conference on Electrical and Electronics Engineering (ELECO), Bursa, Turkey, 28–30 November 2019, pp. 600–604. DOI:10.23919/ELECO47770.2019.8990400.

11. Liang, Y.-H., and Tian, W.-M. Multi-sensor Fusion Approach for Fire Alarm Using BP Neural Network. 2016 International Conference on Intelligent Networking and Collaborative Systems (INCoS), Ostravva, Czech Republic, 7–9 September 2016, pp. 99–102. DOI:10.1109/INCoS.2016.38.

12. Wei Wang, Bo Jiang, and Liping Yang. Design on Fire Alarm System Based on BP Neural Network and Multiple Source Information Fusion. 2014 International Conference on Mechatronics, Control and Electronic Engineering (MCE-14). Advances in Intelligent Systems Research, March 2014, 29-31 August 2014, Shenyang, China, pp. 99–102. URL: <https://doi.org/10.2991/mce-14.2014.21>.

13. Caixia Cheng, Fuchun Sun, and Xinquan Zhou. One Fire Detection Method Using Neural Networks. Tsinghua Science and Technology. Vol. 16, Issue 1, February 2011, pp.31-35. DOI:10.1016/S1007-0214(11)70005-0.

14. Башинський О.І., Пелешко М.З., Пазен О.Ю., Бережанський Т.Г. Вплив температурних режимів пожеж на вогнестійкість будівельних

конструкцій. Пожежна безпека : збірник наукових праць. 2017. №31. С.6-10.

15. ДСТУ Б В.1.1-4-98\*. Захист від пожежі. Будівельні конструкції. Методи випробувань на вогнестійкість. Загальні вимоги. Зі зміною № 1. [Чинний від 2006-01-01]. Вид. офіц. Київ : Держбуд України, 1999. 30 с.

16. Шналь Т.М. Розвиток наукових основ розрахункової оцінки вогнестійкості будівельних конструкцій за умов впливу параметричних температурних режимів пожеж : дис. ... д-ра техн. наук : 21.06.02 / Національний університет "Львівська політехніка". Львів, 2019. 394 с.

17. Md. Rawshan Habib, Naureen Khan, Koushik Ahmed, Mahbubur Rahman Kiran, A.K.M. Asif, Mohaiminul Islam Bhuiyan, and Omar Farrok. Quick Fire Sensing Model and Extinguishing by Using an Arduino Based Fire Protection Device. *Advances in Electrical Engineering (ICAEE): Proceedings of the 5th International Conference, Dhaka, Bangladesh, 26-28 September 2019, Dhaka, 2019, pp. 435–439. DOI: 10.1109/ICAEE48663.2019.8975538.*

18. Гуліда Е.М. Прогнозування величини оптичної густини диму при пожежі в приміщенні. Пожежна безпека : збірник наукових праць. 2011. №18. С.65-70.

19. Коваль О.М. Розвиток наукових основ ліквідації пожеж на деревообробних підприємствах: автореф. дис. ... док. техн. наук: 21.06.02. Харків, 2017. 43 с.

20. ДСТУ EN 54-5:2019. Системи пожежної сигналізації. Частина 5. Сповіщувачі пожежні теплові точкові (EN 54-5:2017 + A1:2018, IDT). [Чинний від 2020-01-01]. Вид. офіц. Київ: ДП "УкрНДНЦ", 2019. 62 с.

21. ДСТУ EN 54-7:2019 Системи пожежної сигналізації. Частина 7. Сповіщувачі пожежні димові точкові розсіяного світла, пропускнуго світла чи іонізаційні (EN 54-7:2018, IDT). [Чинний від 2020-01-01]. Вид. офіц. Київ : ДП "УкрНДНЦ", 2019. 79 с.

22. UL217. - Single and Multiple Station Smoke Alarms. // Underwriters Laboratories. Inc., Northbrook, IL, 60062.

23. BS EN 54-29:2015. Fire detection and fire alarm systems. Multi-sensor fire detectors. Point detectors using a combination of smoke and heat sensors, British Standard, April 2015.

24. ДБН В.2.5-56:2014. Системи протипожежного захисту. [Чинний від 2015-07-01]. Вид. офіц. Київ : Мінрегіон України, 2019. 127 с.

#### References:

1. Roman, J. (2018). "Smoke Signals", NFPA Journal, National Fire Protection Association, Quincy, MA, USA.

2. Chagger, R.; Smith, D. (2014). "The Causes of False Fire Alarms in Buildings", Briefing Paper, BRE Global Limited, Watford, UK.

3. Lesong Wu, Lan Chen, and Xiaoran Hao. (2021). "Multi-Sensor Data Fusion Algorithm for Indoor Fire Early Warning Based on BP Neural Network", MDPI, vol. 12, iss. 12(2), 59. URL: <https://doi.org/10.3390/info12020059>.

4. Yang Feng, Qu Na, and Li Chao. (2017). "Compound Fire Detection Algorithm Based on Fuzzy Neural Network", *Electronics and Control Simulation (MECS 2017), 2nd International Conference on Machinery, Taiyuan, China, June 24-25, 2017. URL: https://doi.org/10.2991/mecs-17.2017.133.*

5. Jing, C., and Jingqi, Fu. (2012). "Fire Alarm System Based on Multi-Sensor Bayes Network", *Procedia Eng, 2012 International Workshop on Information and Electronics Engineering, 2012, vol. 29, pp. 2551–2555. URL: https://doi.org/10.1016/j.proeng.2012.01.349.*

6. Wang, T., Hu, J., Ma, T., and Song, J. (2020). "Forest fire detection system based on Fuzzy Kalman filter", *2020 International Conference on Urban Engineering and Management Science (ICUEMS), Zhuhai, China, April 24–26, 2020, pp. 630–633. DOI:10.1109/ICUEMS50872.2020.00138.*

7. Andrii Kushnir, and Bohdan Kopchak. (2019) "Development of Intelligent Point Multi-Sensor Fire Detector with Fuzzy Correction Block", *2019 IEEE XVth International Conference on the Perspective Technologies and Methods in MEMS Design (MEMSTECH), Polyana, Ukraine, May 22-26, 2019, pp. 41-45. DOI:10.1109/MEMSTECH.2019.8817395.*

8. Andrii Kushnir, and Bohdan Kopchak. (2021). "Development of Multiband Flame Detector with Fuzzy Correction Block", *2021 IEEE XVII International Conference on the Perspective Technologies and Methods in MEMS Design (MEMSTECH), Polyana, Ukraine, May 12-16, 2021, pp. 58-63. DOI:10.1109/MEMSTECH.2019.8817395.*

9. Uduak Umoh, Udoinyang G. Inyang, and Emmanuel E. Nyoho. (2019). "Interval Type-2 Fuzzy Logic for Fire Outbreak Detection", *International Journal on Soft Computing, Artificial Intelligence and Applications (IJSCAI), August 2019, vol. 8, no. 3, pp. 27–46. DOI:10.5121/ijscai.2019.8303.*

10. Mert Nakıp, and Cüneyt Güzeliş. (2019). "Multi-Sensor Fire Detector based on Trend Predictive Neural Network", *11th International Conference on Electrical and Electronics Engineering (ELECO), Bursa, Turkey, November 28–30, 2019, pp. 600–604. DOI:10.23919/ELECO47770.2019.8990400.*

11. Liang, Y.-H., and Tian, W.-M. (2016). "Multi-sensor Fusion Approach for Fire Alarm Using BP Neural Network", *2016 International Conference on Intelligent Networking and Collaborative Systems (INCoS),*

Ostrava, Czech Republic, September 7-9, 2016, pp. 99–102. DOI:10.1109/INCoS.2016.38.

12. Wei Wang, Bo Jiang, and Liping Yang. (2014). “Design on Fire Alarm System Based on BP Neural Network and Multiple Source Information Fusion”, *Advances in Intelligent Systems Research*, 2014 International Conference on Mechatronics, Control and Electronic Engineering (MCE-14), Shenyang, China, August 29-31, 2014, pp. 99–102. URL: <https://doi.org/10.2991/mce-14.2014.21>.

13. Caixia Cheng, Fuchun Sun, and Xinquan Zhou. (2011). “One Fire Detection Method Using Neural Networks”, *Tsinghua Science and Technology*, Vol. 16, Issue 1, pp. 31-35. DOI:10.1016/S1007-0214(11)70005-0.

14. O. Bashynskyi, M. Peleshko, O. Pazen, and T. Berezhanskyi. (2017). “The influence of temperature modes of fire on flexibility of building constructions”, *Fire safety*, no. 31, pp. 6-10.

15. DSTU B B.1.1-4-98\*. *Zahyst vid pozhezhi. Budivelni konstruktsiyi. Metody vyprobuvan na vognestiykist. Zagalni vymogy* [Fire protection. Building structures. Fire resistance test methods. General requirements]. [Effective from 2006-01-01 Kyiv: State Building of Ukraine, 1999. 30 p.

16. T.M. Shnal. (2019). “Development of scientific principles to calculating evaluate of building structures fire resistance under condition of parametric temperature fire regime”, Thesis for a Doctor of Technical Sciences degree, 21.06.02, Lviv Polytechnic National University, Lviv, Ukraine.

17. Md. Rawshan Habib, Naureen Khan, Koushik Ahmed, Mahbubur Rahman Kiran, A.K.M. Asif,

Mohaiminul Islam Bhuiyan, and Omar Farrok. (2019). “Quick Fire Sensing Model and Extinguishing by Using an Arduino Based Fire Protection Device”, *Advances in Electrical Engineering (ICAEE)*, 5th International Conference, Dhaka, Bangladesh, September 26-28, 2019, Dhaka, pp. 435–439. DOI: 10.1109/ICAEE48663.2019.8975538.

18. E. M. Hulida. (2011). “Prediction of absorbancy size of smoke at fire in building”, *Fire safety*, no.18, pp. 65-70.

19. Koval O. M. (2017). “Development of scientific basis of prevention and liquidation of fires for wood-refining enterprises”, The thesis for the degree of doctor of technical sciences, 21.06.02, Kharkiv, Ukraine.

20. BS EN 54-5:2017+A1:2018. Fire detection and fire alarm systems - Part 5: Heat detectors – Point heat detectors, August 2018.

21. BS EN 54-5:2017+A1:2018. Fire detection and fire alarm systems Smoke detectors. Point smoke detectors that operate using scattered light, transmitted light or ionization, September 2018.

22. UL217. Single and Multiple Station Smoke Alarms. // Underwriters Laboratories. Inc., Northbrook, IL, 60062.

23. BS EN 54-29:2015. Fire detection and fire alarm systems. Multi-sensor fire detectors. Point detectors using a combination of smoke and heat sensors, British Standard, April 2015.

24. SBR B.2.5-56:2014. Systemy protypozhezhnogo zahystu [Fire protection systems]. [Effective from 2015-07-01]. Kyiv : Ministry of Regions of Ukraine, 2019. 127 p.

© А. П. Кушнір, Б. Л. Копчак, С. Я. Вовк, 2022.

**Науково-методична стаття.**

Надійшла до редакції 11.11.2022.

Прийнято до публікації 12.12.2022.