

Міністерство освіти і науки України  
Харківський національний університет радіоелектроніки

Факультет  
Кафедра

Комп'ютерної інженерії та управління  
Комп'ютерних інтелектуальних технологій та систем

**КВАЛІФІКАЦІЙНА РОБОТА**  
**Пояснювальна записка**

рівень вищої освіти

другий (магістерський)

Система інтелектуальної ідентифікації  
дефектів плоских поверхонь

Виконав:

студент 2 курсу, групи КІТм-21-1

Юрченко О. В.

Спеціальність 123 Комп'ютерна інженерія

Тип програми освітньо-професійна

Освітня програма Комп'ютерні

інтелектуальні технології

Керівник ст.викл. Ілюнін О.О.

Допускається до захисту

\_\_\_\_\_

(підпис)

Зав. кафедри

\_\_\_\_\_

(підпис)

проф. Руденко О.Г.

2022 р.

Харківський національний університет радіоелектроніки

Факультет	Комп'ютерної інженерії та управління
Кафедра	Комп'ютерних інтелектуальних технологій та систем
Рівень вищої освіти	другий (магістерський)
Спеціальність	123 Комп'ютерна інженерія
Тип програми	освітньо-професійна
Освітня програма	Комп'ютерні інтелектуальні технології

ЗАТВЕРДЖУЮ:

Зав. кафедри \_\_\_\_\_  
(підпис)

“ \_\_\_\_ ” \_\_\_\_\_ 20\_\_ р.

## ЗАВДАННЯ

### НА КВАЛІФІКАЦІЙНУ РОБОТУ

студентові \_\_\_\_\_ Юрченко Олександр Вікторовичу  
(прізвище, ім'я, по батькові)

1. Тема роботи Система інтелектуальної ідентифікації  
дефектів пласких поверхонь

затверджена наказом по університету від “ 08 ” листопада 2022 р. № 1666 Ст

2. Термін подання студентом роботи до екзаменаційної комісії 10.12.2022

3. Вхідні дані до роботи \_\_\_\_\_

- 1) виявлення основних характеристик об'єкту керування та вимог до системи регулювання;
- 2) побудова тестової моделі нейронної мережі регулятора;
- 3) побудова тестової моделі нечіткого класифікатора температурних завдань;
- 4) середовище моделювання – Simulink, Matlab;
- 5) мова програмування – C++; IDE Processing;

4. Перелік питань, що потрібно опрацювати в роботі \_\_\_\_\_

- 1) огляд предметної області;
- 2) аналіз об'єкту дослідження;
- 3) обзор нейронних мереж;
- 4) дослідження систем ідентифікації;
- 5) розробка системи інтелектуальної ідентифікації дефектів пласких поверхонь;
- 6) критерій якості обробки дефектів;
- 7) експериментальні дослідження;
- 8) висновки.

5. Перелік графічного матеріалу із зазначенням креслеників, схем, плакатів, комп'ютерних ілюстрацій (слайдів) Слайди- 12 арк. ф. А4

---

---

---

---

6. Консультанти розділів роботи (заповнюється за наявності консультантів згідно з наказом, зазначеним у п.1 )

Найменування розділу	Консультант (посада, прізвище, ім'я, по батькові)	Позначка консультанта про виконання розділу	
		підпис	дата

### КАЛЕНДАРНИЙ ПЛАН

№	Назва етапів роботи	Термін виконання етапів роботи	Примітка
1	Видача та узгодження теми проєкту	01.09.2022	виконано
2	Огляд стану проблеми та постановка задачі	01.09-14.09	виконано
3	Аналіз літератури за напрямком магістерської роботи	14.09-21.09	виконано
4	Аналіз роботи професійних навичок фахівця	21.09-28.09	виконано
5	Аналіз інтелектуальних систем підтримки прийняття рішень	21.09-28.09	виконано
6	Розробка тестової нейронної мережі	28.09-12.10	виконано
7	Експериментальні дослідження	12.10-02.11	виконано
8	Підготовка графічного матеріалу	23.11-07.12	виконано
9	Перевірка виконаного проєкту керівником	10.12.2022	виконано
10	Захист проєкту	19.12.2022	виконано

Дата видачі завдання 08 листопада 2022 р.

Студент \_\_\_\_\_

Керівник роботи \_\_\_\_\_ Ст.викл. Ілюнін О.О., к.т.н. \_\_\_\_\_

## РЕФЕРАТ

Пояснювальна записка кваліфікаційної магістерської роботи містить: 64 ст., 25 рис., 3 табл., 2 дод., 20 джерел.

ІНТЕЛЕКТУАЛЬНІ СИСТЕМИ ІДЕНТИФІКАЦІЇ, НЕЙРОННА МЕРЕЖА, НЕЧІТКИЙ КЛАСИФІКАТОР, C.#, PROCESSING.

Предметом дослідження є неронечіткі моделі та методи інтелектуальної ідентифікації дефектів 2D поверхонь на прикладі технологічного процесу виробництва сталевго прокату за умов поточної невизначеності кількості та характеристик дефектів.

Об'єктом дослідження є процеси ідентифікації дефектів пласких поверхонь на прикладі поверхні сталевго прокату.

Метою роботи є розробка системи інтелектуальної ідентифікації дефектів пласких поверхонь, що оброблюються в безперервних технологічних процесах, з використанням нечіткого та непромереженого підходів.

Для досягнення поставленої мети було виконано наступні завдання:

- обзор літератури та аналіз сучасних рішень;
- синтез нейронечіткої мережевої моделі ідентифікації дефектів поверхні сталевго прокату;
- імітаційне моделювання та тестовий експеримент роботи системи інтелектуальної ідентифікації дефектів поверхні сталевго прокату;
- удосконалення методу оцінювання якості функціонування ділянок технологічного процесу, який на відміну від існуючих використовує кластеризацію залишків дефектів поверхні прокату на виході процесу.

Методи дослідження. Під час розв'язання поставлених задач у роботі використовувалися комбінації наступних методів: системного аналізу та

синтезу; методів нечіткої кластеризації та теорії штучних нейронних мереж у комбінації з технологіями «комп'ютерного зору», що дозволило розробити в середовищі NeuroPh моделі, призначені для ідентифікації дефектів плоских поверхонь сталевого прокату; методів імітаційного моделювання в середовищі ScieLab. Здійснений тестовий експеримент та аналіз синтезованої моделі підтвердив її ефективність.

Практичне використання розробленої системи лежить в оцінюванні якості готової продукції та якості функціонування контурів керування ділянками технологічного процесу за залишками дефектів поверхні прокату відповідних класів на виході з процесу.

## ABSTRACT

Explanatory note of master's qualification work: 64 pages, 25 figures, 2 tables, 2 appendix, 20 sources.

INTELLIGENT CONTROL SYSTEMS, NEURAL NETWORK, FUZZY CLASSIFIER, C#, PROCESSING.

The subject of the study is fuzzy models and methods of intelligent identification of defects of 2D surfaces on the example of the technological process of rolling steel production under conditions of current uncertainty of the number and characteristics of defects.

The object of research is the process of identifying defects of flat surfaces on the example of the surface of rolled steel.

The aim of the work is to develop a system of intelligent identification of defects of flat surfaces, which are processed in continuous technological processes, using fuzzy and neural network approaches.

To achieve the goal, the following tasks were performed:

- literature review and analysis of modern solutions;
- synthesis of a neuro-fuzzy network model for identifying defects on the surface of rolled steel;
- simulation modeling and test experiment of the system of intellectual identification of defects on the surface of rolled steel;
- improvement of the method of assessing the quality of the functioning of technological process sections, which, unlike the existing ones, uses the clustering of the remaining defects of the surface of the rolled product at the end of the process.

Research methods. During the solution of the set tasks, combinations of the following methods were used in the work: system analysis and synthesis; methods

of fuzzy clustering and the theory of artificial neural networks in combination with "computer vision" technologies, which made it possible to develop in the NeuroPh environment models intended for the identification of defects on flat surfaces of rolled steel; simulation modeling methods in the ScieLab environment. The conducted test experiment and analysis of the synthesized model confirmed its effectiveness.

The practical use of the developed system lies in the evaluation of the quality of the finished products and the quality of the functioning of the control circuits of the sections of the technological process based on the remaining surface defects of the rolled products of the corresponding classes at the exit from the process.

Міністерство освіти і науки України  
Харківський національний університет радіоелектроніки

Факультет                      Комп'ютерної інженерії та управління  
Кафедра                        Комп'ютерних інтелектуальних технологій та систем

**АНОТАЦІЯ**  
**КВАЛІФІКАЦІЙНОЇ РОБОТИ**

рівень вищої освіти                      другий (магістерський)

Система інтелектуальної ідентифікації  
дефектів плоских поверхонь

Виконав:

студент 2 курсу, групи КІТм-21-1

Сапега О.А.

Спеціальність 123 Комп'ютерна інженерія

Тип програми: освітньо-професійна

Освітня                      програма                      Комп'ютерні  
інтелектуальні технології

Керівник    ст.викл. Ілюнін О.О.

2022 р.

## АНОТАЦІЯ

Юрченко О. В. Система інтелектуальної ідентифікації дефектів пласких поверхонь. – Магістерська кваліфікаційна робота.

Актуальність теми. Останнім часом у безлічі технологічних процесів (ТП) набули широкого поширення цифрові системи статистичного обліку дефектів продукції, що дозволило упорядити контроль якості кінцевого продукту. Серед цих процесів є безперевні, ті, що випускають продукцію з пласкими поверхнями (виробництво фанери, тканин, папіру, металевого прокату, шліфованої натуральної шкіри для одягу та взуття, тощо); поява на поверхні продукції дефектів має стохастичне походження, а несвоєчасне їх виявлення та видалення приводить виробника до суттєвих витрат: зниження сортності, повертання.

З другого боку на сьогоднішній день набули розвитку та поширились у застосуванні методи «комп'ютерного зору» та високошвидкісної обробки зображень за допомогою інтелектуальних нейромереж та нечітких методів. Взавши до уваги безперечний факт щорічного здешевлення електронних оптичних засобів, програмного забезпечення, зростаючий попит виробників на впровадження новітніх технологій можна впевнено зробити висновок про насущність тематики даної роботи.

Побудова автоматизованої системи керування (АСК) ділянками металургійного виробництва передбачає необхідність вирішення ряду взаємопов'язаних завдань керування та контролю якості продукції після кожного етапу виробництва. Достатньо цікавим з точки зору утворення ознак та характеристик як об'єкту є дефекти, що утворюються на поверхні сталевих прокату в металургії. Тому процедуру їх ідентифікації буде розглянуто в роботі як приклад. Для цього доцільно розробити програмні додатки ідентифікації дефектів поверхні металу «забруднень» окалиною і оксидними плівками.

Для обліку всіх факторів ТП необхідна побудова математичних моделей, які, з одного боку, повинні найбільш повно відображати властивості досліджуваного об'єкта, а з іншого – бути зручними для реалізації алгоритмів ідентифікації та керування.

Розробка цифрових систем керування ТП повинна супроводжуватися як вдосконаленням алгоритмів, так і вдосконаленням технічної бази реалізації. На сучасному етапі рівня розвитку технічних засобів на передній план висувуються вимоги підвищення точності: стабілізації технологічних параметрів, їх вимірювань та оцінок в умовах нестационарних постійно діючих збурень ТП, обумовлених стохастичною кількістю утворюваної окалини.

«Розумною», перспективною альтернативою класичним вибірковим статистичним методам ідентифікації дефектів є використання комбінації технологій «комп'ютерного зору» та штучних нейронних мереж (ШНМ). Найбільш корисною властивістю ШНМ є їх здатність до навчання за допомогою навчальних процедур, заснованих на аналізі співвідношень "вхід-вихід". Це дозволяє отримати досить прості, конкурентні на ринку технічних засобів рішення, а присутність нейронів з нелінійними функціями активації в структурі ШНМ дозволяє впроваджувати їх для вирішення складних завдань ідентифікації, що потребують достатньої точності, – в промисловості.

Ефективним засобом розробки та оцінки якості та ефективності нових алгоритмів є використання універсальних програмних комплексів моделювання систем ( ScieLab, Neuroph). На етапі проектування важливим є детальний аналіз процесів в контурах АСК та вплив на них різноманітних зовнішніх і внутрішніх збурень, змін умов експлуатації, параметрів ТП. На додаток, існуючі математичні моделі процесів, які використовуються для розробки і корекції технологічних режимів роботи ТП, досить громіздкі, і не можуть врахувати вплив на якість системи керування багатьох чинників.

Ефективне керування та ідентифікація ТП є можливими за умов впровадження більш точних моделей та методів, що мають бути

нечутливими до суттєвих завад та похибок вимірів. Таким вимогам задовольняють інтелектуальні методи контролю, ідентифікації та керування динамічними системами, що експлуатуються за умов суттєвої невизначеності щодо характеристик керованого об'єкту та зовнішнього середовища на основі об'єднання принципів теорії нечіткого керування та штучних нейронних мереж.

Близько 15% валютних надходжень до бюджету України становить експорт листового прокату, в тому числі і холоднокатаний лист. Видалення окалини з поверхні листа є важливим технологічним процесом (ТП), який визначає якість вихідної продукції. Технічна досконалість даного процесу визначає вихідну продуктивність лінії прокату. Процес травління листової сталі полягає в очищенні поверхні листа від шару окалини в процесі хімічної реакції кислотного розчину з оксидами заліза, що формують шар окалини.

Результативна ідентифікація об'єктів ТП в умовах невизначеності діє на основі використання робастних, більш точних, нечутливих до похибок вимірювання динамічних і статичних моделей. Такі моделі повинні легко адаптуватися та бути адекватними. Зазначеним вимогам найбільше задовольняють інтелектуальні нечіткі і ШНМ–методи контролю, ідентифікації та керування динамічними об'єктами.

Сучасна тенденція спільного використання методів нечіткої логіки і нейромережових методів для створення комбінованих систем інтелектуального ідентифікації дозволить досить формально враховувати зміни якості продукції та співвідносити її з порушенням регламенту в деяких контурах керування ТП, що відсутнє в існуючих системах керування. Такий підхід дозволить значною мірою усунути недоліки, властиві традиційним системам керування, побудованим на основі статистичних моделей [3], та суттєво підвищити якість оброблюваної поверхні прокату за умов додаткової економії енергоспоживання та ресурсів.

Таким чином, синтез цифрових систем автоматизованої ідентифікації дефектів плоских поверхонь, що базуються на використанні інтелектуальних

моделей та методів є актуальною науково-практичною задачею.

Метою роботи є розробка системи інтелектуальної ідентифікації дефектів плоских поверхонь на прикладі поверхні сталевого прокату, з використанням нечіткого та нейромережевого підходів.

Для досягнення поставленої мети необхідно виконати наступні завдання:

- обзор літератури та аналіз сучасних сучасних рішень;
- синтез нейронечіткої мережевої моделі ідентифікації дефектів поверхні сталевого прокату;
- імітаційне моделювання та тестовий експеримент роботи системи інтелектуальної ідентифікації дефектів поверхні сталевого прокату;
- удосконалення методу оцінювання якості вихідної продукції та функціонування ділянок технологічного процесу, який на відміну від існуючих використовує кластеризацію залишків дефектів поверхні прокату на виході процесу.

Об'єктом дослідження є процеси ідентифікації дефектів плоских поверхонь на прикладі поверхні сталевого прокату.

Предметом дослідження є неронечіткі моделі та методи інтелектуальної ідентифікації дефектів 2D поверхонь на прикладі технологічного процесу виробництва сталевого прокату за умов поточної невизначеності кількості та характеристик дефектів.

Методи дослідження. Під час розв'язання поставлених задач у роботі використовувалися комбінації наступних методів: системного аналізу та синтезу, методів нечіткої кластеризації та теорії штучних нейронних мереж у комбінації з технологіями «комп'ютерного зору», що дозволили запропонувати розроблені в середовищі NeuroPh моделі, що призначені для ідентифікації дефектів плоских поверхонь на прикладі технологічного процесу виробництва сталевого прокату; методів імітаційного моделювання в середовищі ScieLab, що дозволили здійснити тестовий експеримент та аналіз синтезованої моделі, тлумачення результатів, і підтвердити ефективність

отриманих результатів та розробити рекомендації щодо їх практичного використання.

Наукова новизна отриманих результатів. В рамках виконання роботи отримані наступні результати, що визначають наукову новизну кваліфікаційної роботи:

– удосконалено процес ідентифікації дефектів поверхні сталевого прокату з використанням методів нечіткої кластеризації та штучних нейронних мереж, що дозволить автоматизувати контроль якості кінцевого продукту та оперативно оцінювати в процесі товщину дефектів;

– отримав подальший розвиток метод оцінювання якості керування певними ділянками технологічної лінії травління, який на відміну від існуючих використовує кластеризацію залишків дефектів поверхні прокату на виході технологічного процесу для змін стратегій та режимів у керуючих контурах відповідних ділянок технологічної лінії.

Для досягнення поставленої мети були вирішено ряд теоретичних і практичних завдань.

У першому розділі визначено особливості утворення дефектів поверхні сталевого прокату. Наведено огляд існуючих рішень ідентифікації дефектів, загальні принципи прийнятого до виконання рішення та обґрунтовано доцільність його використання. Здійснено аналіз завдання, сформульовано *мету і задачі* проекту.

У другому розділі представлено модифікації методів інтелектуальної (нечіткої та нейромережевої) ідентифікації, що використані для розробки математичних моделей елементів системи інтелектуальної ідентифікації дефектів плоских поверхонь на прикладі поверхні сталевого прокату.

Для здійснення процедур ідентифікації в роботі запропоновано комбіноване використання модифікацій штучних нейронних радіально-базисних мереж (РБМ) та нечіткої кластеризації (Fuzzy Clustering Method). Відповідні алгоритми ідентифікації мають достатню швидкість збіжності, не

потребують багато обчислювального ресурсу та придатні для роботи в складі системи ідентифікації в реальному часі.

У третьому розділі наведено результати тестового експерименту по ідентифікації характерних дефектів і оцінювання їх ознак.

У четвертому розділі висвітлено аспекти практичної цінності системи ідентифікації дефектів: оцінювання якості готової продукції та якості функціонування контурів керування ділянками технологічного процесу за залишками дефектів поверхні прокату відповідних класів на виході з процесу.

## ІНТЕЛЕКТУАЛЬНІ СИСТЕМИ РЕГУЛЮВАННЯ, НЕЙРОННА МЕРЕЖА, НЕЧІТКИЙ КЛАСИФІКАТОР, C.#, PROCESSING.

Використані в роботі публікації здобувача, керівника та співробітників кафедри:

1. Pyunin O.O., Khodak M.V., Yurchenko O.V., Sapcha O.A. Fuzzy estimation procedure of the concentration of the components of a sulfuric acid pickling solution. ISSN 2078-0625 (online). Інтегровані технології та енергозбереження. Щоквартальний науково-практичний журнал. – Харків: НТУ «ХПІ», 2022. – № 3, с.63-75. Фахове видання. Доступно за адресою: [https://docs.google.com/document/d/1VivXA87odmmdxCISdkXJG\\_Jpc1DRjSvF/edit?usp=share\\_link&oid=118443346938890580156&rtpof=true&sd=true](https://docs.google.com/document/d/1VivXA87odmmdxCISdkXJG_Jpc1DRjSvF/edit?usp=share_link&oid=118443346938890580156&rtpof=true&sd=true)

2. О. Ілюнін, С. Удовенко, М. Ходак, О. Юрченко, О. Сапега, Інтелектуальна ідентифікація дефектів металопрокату з застосуванням технологій «комп'ютерного зору». Україна, Вінниця, конференція "Контроль і управління в складних системах", 2022-11-15, (Vinnytsia), КУСС-2022. URL: <<https://conferences.vntu.edu.ua/index.php/mccs/mccs22/index>>.

3. Руденко О. Г. Искусственные нейронные сети: архитектуры, обучение, применения / О. Г. Руденко, Е. В. Бодянский. – Харьков: ТЕЛЕТЕХ, 2004. – 370 с.

4. O.Bezsonov, O.Ilyunin, A.Khusanov, O.Rudenko, O.Sotnikov. Intelligent Identification System of the Process Liquid Solutions Composition. COLINS-2022: *6th International Conference on Computational Linguistics and Intelligent Systems*, May 12–13, 2022, Gliwice, Poland URL: <<https://ceur-ws.org/Vol-3171/paper69.pdf>>

## ЗМІСТ

Перелік умовних позначень, скорочень і термінів .....	17
Вступ.....	18
1 Аналіз предметної області і постановка задачі.....	21
1.1 Особливості утворення дефектів поверхні сталевого прокату .....	21
1.2 Обґрунтування проектних рішень.....	24
1.3 Прийняті методи машинного навчання .....	30
1.4 Постановка задачі.....	32
2 Математичний апарат побудови системи.....	36
2.1 Використання нечітких і нейромережових моделей в задачах ідентифікації дефектів на 2D поверхнях .....	36
2.2. Нечіткий класифікатор дефектів поверхні сталевого прокату.....	38
2.3 Технології комп'ютерного зору .....	44
3 Інтелектуальна ідентифікація товщини дефектів .....	49
3.1 Налаштування РБМ-моделі.....	49
3.2 Результати тестового експерименту .....	50
4 Застосування системи ідентифікації дефектів в технологічному процесі ..	51
4.1 Критерій якості обробки поверхні.....	51
4.2 Оцінювання якості роботи технологічного процесу .....	52
Висновки .....	54
Перелік джерел посилання .....	55
Додаток А Графічний матеріал кваліфікаційної роботи.....	57

## ПЕРЕЛІК УМОВНИХ ПОЗНАЧЕНЬ, СКОРОЧЕНЬ І ТЕРМІНІВ

АСК – автоматизована система керування;

АКТЗ – автоматизований комплекс технічних засобів;

БП – багатошаровий персептрон;

ВНД – виявлення несправностей і діагностика;

МРНК – модифікований рекурентний метод найменших квадратів;

РБМ – радіально-базисна мережа;

ТП – технологічний процес;

ОК – об'єкт керування;

ШНМ – штучна нейронна мережа;

ANFIS – Adaptive-Network-Based Fuzzy Inference System (адаптивна мережа нечіткого виведення);

BP – Back-propagation (зворотне поширення помилки);

GDR – Generalized Delta Rule (узагальнене дельта-правило);

MISO – (multi-input-simple-output) – багатопараметричний об'єкт керування

NARMA – нелінійна ARMA-модель;

SISO – (simple-input-simple-output) однопараметричний об'єкт керування

## ВСТУП

Останнім часом у безлічі технологічних процесів (ТП) набули широкого поширення цифрові системи статистичного обліку дефектів продукції, що дозволило упорядити контроль якості кінцевого продукту. Серед цих процесів є безперевні, ті, що випускають продукцію з плоскими поверхнями (виробництво фанери, тканин, папіру, металевого прокату, шліфованої натуральної шкіри для одягу та взуття, тощо); поява на поверхні продукції дефектів має стохастичне походження, а несвоєчасне їх виявлення та видалення приводить виробника до суттєвих витрат: зниження сортності, повертання.

З другого боку на сьогоднішній день набули розвитку та поширились у застосуванні методи «комп'ютерного зору» та високошвидкісної обробки зображень за допомогою інтелектуальних нейромереж та нечітких методів. Взавши до уваги безперечний факт щорічного здешевлення електронних оптичних засобів, програмного забезпечення, зростаючий попит виробників на впровадження новітніх технологій можна впевнено зробити висновок про насущність тематики даної роботи.

Побудова автоматизованої системи керування ділянками металургійного виробництва передбачає необхідність вирішення ряду взаємопов'язаних завдань керування та контролю якості продукції після кожного етапу виробництва. Окремі задачі для ділянки травління дефектів сталевих прокату були вирішені та описані за допомогою інтелектуальних методів та моделей [1-4]. Достатньо цікавим з точки зору утворення, ознак та характеристик як об'єкту є дефекти, що утворюються на поверхні сталевих прокату в металургії. Тому процедуру їх ідентифікації буде розглянуто в роботі як приклад. Для цього доцільно розробити програмні додатки ідентифікації дефектів поверхні металу «забруднень» окалиною і оксидними плівками.

Для обліку всіх факторів ТП необхідна побудова математичних моделей, які, з одного боку, повинні найбільш повно відображати властивості досліджуваного об'єкта, а з іншого – бути зручними для реалізації алгоритмів ідентифікації та керування.

Розробка цифрових систем ідентифікації повинна супроводжуватися як вдосконаленням алгоритмів, так і вдосконаленням технічної бази реалізації. На сучасному етапі рівня розвитку технічних засобів на передній план висуваються вимоги підвищення точності: стабілізації технологічних параметрів, їх вимірювань та оцінок в умовах нестационарних постійно діючих збурень ТП, обумовлених стохастичною кількістю утворюваної окалини.

«Розумною», перспективною альтернативою класичним вибірковим статистичним методам ідентифікації дефектів є використання комбінації технологій «комп'ютерного зору» та штучних нейронних мереж (ШНМ) [6,7]. Найбільш корисною властивістю ШНМ є їх здатність до навчання за допомогою навчальних процедур, заснованих на аналізі співвідношень "вхід-вихід". Це дозволяє отримати досить прості, конкурентні на ринку технічних засобів рішення, а присутність нейронів з нелінійними функціями активації в структурі ШНМ дозволяє впроваджувати їх для вирішення складних завдань ідентифікації в промисловості, що потребують достатньої точності.

Ефективним засобом розробки та оцінки якості та ефективності нових алгоритмів є використання універсальних програмних комплексів моделювання систем ( ScieLab, Neuroph). На етапі проектування важливим є детальний аналіз процесів в контурах керування та вплив на них різноманітних зовнішніх і внутрішніх збурень, змін умов експлуатації, параметрів ТП. На додаток, існуючі математичні моделі процесів, які використовуються для розробки і корекції технологічних режимів роботи ТП, досить громіздкі, і не можуть врахувати вплив на якість системи керування багатьох чинників.

Ефективне керування та ідентифікація ТП є можливими за умов впровадження більш точних моделей та методів, що мають бути нечутливими до суттєвих завад та похибок вимірів. Таким вимогам задовольняють інтелектуальні методи контролю, ідентифікації та керування динамічними системами, що експлуатуються за умов суттєвої невизначеності щодо характеристик керованого об'єкту та зовнішнього середовища на основі об'єднання принципів теорії нечіткого керування та штучних нейронних мереж. Близько 15% валютних надходжень до бюджету України становить експорт листового прокату, в тому числі і холоднокатаний лист. Видалення окалини з поверхні листа є важливим технологічним процесом (ТП), який визначає якість вихідної продукції. Технічна досконалість даного процесу визначає вихідну продуктивність лінії прокату. Процес травління листової сталі полягає в очищенні поверхні листа від шару окалини в процесі хімічної реакції кислотного розчину з оксидами заліза, що формують шар окалини.

Результативна ідентифікація об'єктів ТП в умовах невизначеності діє на основі використання робастних, більш точних, нечутливих до похибок вимірювання [2-6] динамічних і статичних моделей. Такі моделі повинні легко адаптуватися та бути адекватними. Зазначеним вимогам найбільше задовольняють інтелектуальні нечіткі і ШНМ–методи контролю, ідентифікації та керування динамічними об'єктами.

Сучасна тенденція спільного використання методів нечіткої логіки і нейромережових методів для створення комбінованих систем інтелектуального ідентифікації дозволить досить формально враховувати зміни якості продукції та співвідносити її з порушенням регламенту в деяких контурах керування ТП, що відсутнє в існуючих системах. Такий підхід дозволить значною мірою усунути недоліки, властиві традиційним системам ідентифікації, побудованим на основі статистичних моделей [3], та суттєво підвищити якість оброблюваної поверхні прокату за умов додаткової економії енергоспоживання та ресурсів.

Таким чином, синтез цифрових систем автоматизованої ідентифікації

дефектів плоских поверхонь, що базуються на використанні інтелектуальних нейронечітких моделей та методів та комп'ютерного зору є актуальною науково-практичною задачею.

## 1 АНАЛІЗ ПРЕДМЕТНОЇ ОБЛАСТІ І ПОСТАНОВКА ЗАДАЧІ ДОСЛІДЖЕННЯ

Розпізнавання образів динамічних об'єктів, в основі якого лежать методи штучного інтелекту є новим перспективним напрямом задач ідентифікації.

Нейронні мережі володіють властивостями, які роблять їх унікальним інструментом створення систем ідентифікації: здатністю до навчання на прикладах та до узагальнення даних, високою швидкістю в силу архітектурного паралелізму, закладеного в ШНМ їх математичною будовою. Перспективність застосування систем нейромережевого керування обумовлена наступними факторами:

- ШНМ є адаптивними системами, здатними навчатися для вирішення складних завдань керування;
- нейромережеві технології керування дозволяють подолати багато труднощів, що виникають при роботі з нелінійними об'єктами. Здатність ШНМ реалізувати складні нелінійні відображення обумовлена застосуванням сигмоїдальних функцій активації (або деяких нелінійних функцій загального вигляду) для нейронів в прихованих шарах;
- здатність ШНМ до самонавчання дозволяє використовувати нейрорегулятори навіть в умовах суттєвих невизначеностей;

Висока швидкодія і надійність нейрорегулятора обумовлені високим ступенем паралельності ШНМ. Простота реалізації нейронних мереж і їх здатність до навчання роблять їх особливо привабливими при застосуванні в реальному часі

### 1.1 Особливості утворення дефектів поверхні сталевого прокату

Дефекти поверхні смуги виникають на різних стадіях обробки. При

неякісному контролю процесу травління гарячекатаних смуг можливі недотрав і перетрав. Рівень наявності дефектів оцінюється за допомогою узагальнених характеристик якості. Утворені дефекти смуги за фізико-механічними властивостями залежать головним чином від термічних режимів охолодження рулонів та режимів деформації.

Кількість, склад і товщина окалини змінюються в залежності від локалізації по поверхні всієї довжини рулону, умов і часу його рулонування та охолодження і є фактором невизначеності ТП [1].

Товщини оксидних плівок кольорів мінливості (утворюються при  $250 \div 350 \text{ }^\circ\text{C}$ ) сумірні з довжинами хвиль видимих кольорів спектру (рис.1.1).




Рис.1.1 – Схема розміщення окалини на гарячекатаній смугі (перетин)

Нумерація позицій (1–10) на рис.1.1 відповідає значенням  $n$  в таблиці 1 товщин оксидних плівок  $\delta_n$ , представлених у вигляді нечітких LR – інтервалів  $(D_n, c_n)$ .

Кожному з дефектів відповідає своя температура утворення при охолодженні та товщина плівки. Таким чином, окалина зростає як назовні, так і всередину від поверхні прикордонного шару, та як видно з рис.1.1 «наростають» послідовно один на одній.

Таблиця 1.1 – Характеристика оксидних плівок

n	X <sub>m</sub> = Колір	T <sub>утворення</sub> , °C	Товщина оксидної плівки $\delta_n = (D_n, c_n)$ , Å	
			D <sub>n</sub>	c <sub>n</sub>
1	Солом'яний	220	425	35
2	Золотистий	230	495	25
3	Коричневий	240	500	30
4	Червоно-коричневий	250	540	40
5	Пурпурний	260	595	35
6	Фіолетовий	260	660	35
17	Синій	300	690	40
8	Волошковий	немає даних	860	75
9	Темно-сірий		900	80
10	Майже чорний		1200	110

Товщину шару окалини і її якісний склад, які впливають на швидкість травління, необхідно враховувати як фактор невизначеності в силу складності прямого виміру безпосередньо в ТП та побічних ефектів [3]. Додатковим фактором невизначеності є утворення несистемних дефектів (НД) областей з вкатаними точковими залишками окалини і металевої крихти, починаючи з етапу формування слябів (табл.1.2).

Таблиця 1.2 – Характеристика несистемних дефектів

n	X <sub>m</sub> = Колір	$\delta_n$ , мк
1	Матовий алюміній	0,1÷0,4
2	Блідо-голубий	5÷10
3	Світло-сірий	13÷15
4	Сірий	Дані відсутні
5	Темно-сірий	24÷36
6	Темно-сірий матовий	Дані відсутні
7	Майже чорний	34÷40

Форма загального розподілу системних дефектів по поверхні рулону схематично представлена на рис. 1.2, де: 1 – область утворення оксидних плівок, 2 – область пухкого шару, 3 – область утворення товстого шару щільної окалини, стрілкою зазначено напрям до верхньої частини рулону в період його охолодження.

Інтервальні оцінки товщини дефектів, їх випадковий нерівномірний розподіл по поверхні смуги допускає віднесення технологічного процесу травління смугової сталі до класу об'єктів інтелектуального нейронечіткого керування [3, 4]. Крім того, на якість процесу впливають деякі неконтрольовані параметри (в тому числі площа та товщина дефектів), що створюють невизначеність його опису та низьку ефективність застосування традиційних схем автоматизованого керування. Окрім того, для забезпечення зворотного зв'язку з декількома контурами керування В ТП необхідний контроль якості поверхні після обробки.



Рис.1.2 – Схема загального розподілу окалини по поверхні рулону

## 1.2 Обґрунтування проектних рішень

Відсутність апріорної інформації про несистемні дефекти (НД) (кількість, форму, розміри) призводить до методики застосування нечіткої

кластеризації вхідних даних  $Im^{in}$ . Для забезпечення мінімальної помилки геометричної нерозрізненості НД, що знаходяться в безпосередній близькості один від одного при впливі фонових помилок телеметричної апаратури, було запропоновано метод вхідної сегментації наборів позиційних координат з реєстрацією даних про форму НД [5] для налаштування нечіткого регулятора ТП в подальшому.

На відміну від [5], де накопичувалася статистика НД на вибірці з партії рулонів і був відсутній вихідний контроль  $Im^{out}$ , в [6] була запропонована схема БТА з компараторною ідентифікацією дефектів прокату, що підлягають попередньому селективному та/або системному травленню, що згладжує (рис.1.3).

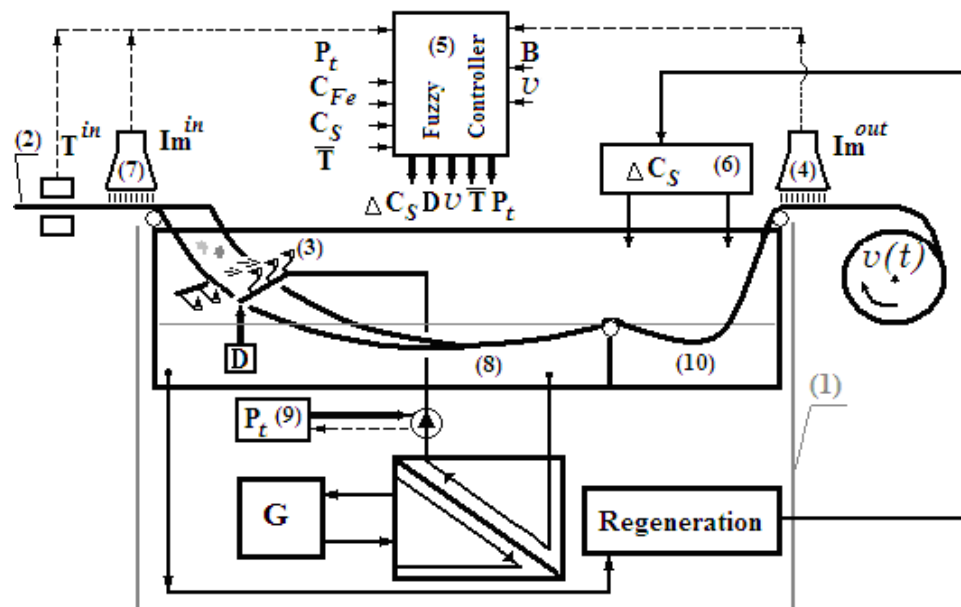


Рис.1.3 – Схема НТА з ідентифікацією та позиціонуванням несистемних дефектів смуги сталевих прокату

Пристрій містить:

1 – травильний агрегат з вузлами нагріву рекуперації та регенерації травильного розчину;

2 – металеву смугу;

3 – блок для подачі травильного розчину через  $N$  сопел, розташованих по обидва боки площини металеві смуги, що рухається, з регульованим

тиском  $P_i$ ;

4 – оптичний датчик вихідного контролю якості травлення металевієї смуги з обох сторін;

5 – блок обробки оптичної інформації та управління технологічним процесом;

6 – дозатор;

7 – оптичний датчик вхідної ідентифікації та позиціонування несистемних дефектів металевієї смуги з обох сторін;

8 – ванна зрошення травильного агрегату;

9 – другий дозатор;

10 – комплекс занурювальних травильних ванн (або одну травильну ванну).

Отримуючи дані від (7) контролер (5) визначає позиційні координати дефекту  $D^m$  у вигляді прямокутника з координатами  $(x^{1m}, y^{1m}) - (x^{2m}, y^{2m})$  і формує сигнал на (3) для включення сопел  $N_j$  ( $j=i, i+1, \dots, k$ ) на період часу  $T_j = (y^{2m} - y^{1m}) / V(t)$ . Причому зрошення сопел  $N_j$  покриває дефект  $D^m$  на ділянці смуги шириною  $[x^{1m}, x^{2m}]$ .

Система ідентифікації вимагала постійного оновлення бази еталонів НД та підлаштування регуляторів у контурах. Достаньо складно розглядати ідентифікацію дефектів в ТП як ізольований контур, тому що результати ідентифікації використовують інші контури керування як вхідні дані.

При виконанні ТП, завдяки впливу нестационарних збурень, параметри можуть сягати критичних меж, хоча самі ці межі критичних станів і алгоритми виходу з них можуть бути описані досить прозорими моделями та задані чіткими регламентами. Для розв'язання задач підтримки вихідних параметрів ТП в регламентованих межах, за умови дії нестационарних збурень, існує ряд ефективних рішень [2]. Стійкість керованої системи забезпечується за рахунок використання супервізора  $R_{NNS}$  на основі ШНМ – моделі в допомогу основному регулятору  $R1$  контура керування  $C1$  (або

групи регуляторів  $R_n$ , які здійснюють керування об'єктом по незалежних контурах  $C_n$ ). Супервізор завдяки даним системи ідентифікації дефектів поверхні та стану ТП відстежує стан і входи об'єкта керування. Якщо стан системи під впливом збурення  $d$  виходить за встановлені межі  $M_x$  (стає потенційно небезпечним або неприйнятним за регламентними обмеженнями), то супервізор запускає стабілізуючу дію  $v_2$ , щоб повернути об'єкт в область допустимих станів  $M_0$ .

Якщо результат виконання стабілізуючої дії незадовільний, то сигнал  $v_1$  здійснює відключення сигналу  $u_i$ , керуючого  $i$ -м контуром керування.

Схему керування БТА, прототип якої наведено в [1], представлено на рис.1.4.

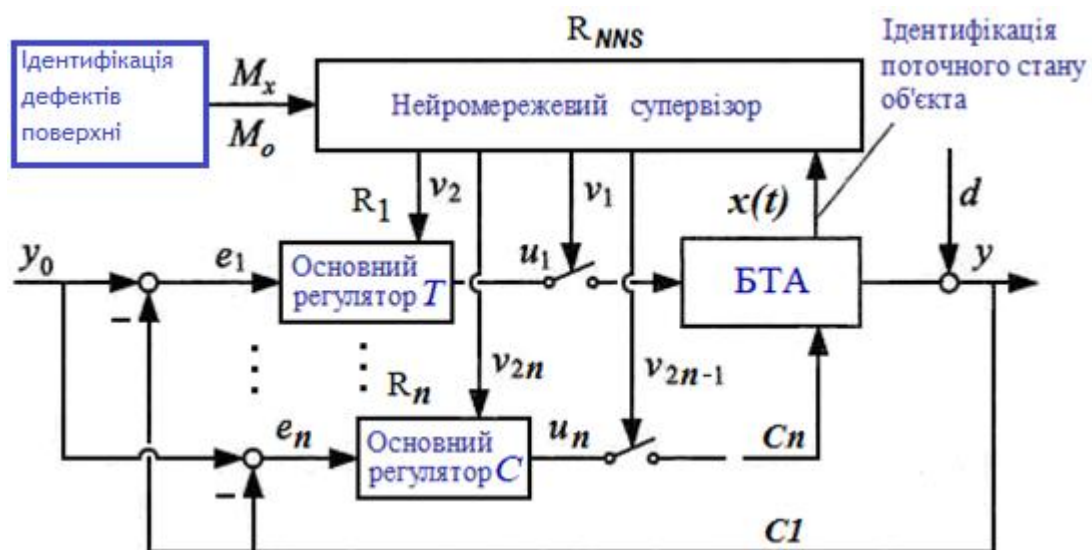


Рисунок 1.8 – Неймережевий супервізор забезпечення стійкості керування нелінійними системами.

Супервізор відстежує стан і входи об'єкта керування. Якщо стан системи під впливом збурення  $d$  виходить за встановлені межі  $M_x$  (стає потенційно небезпечним), то супервізор запускає стабілізуючу дію  $v_i$ , щоб повернути об'єкт в область допустимих станів  $M_0$ . Якщо результат виконання стабілізуючої дії незадовільний, то сигнал  $v_i$  здійснює відключення вхідного

сигналу  $u_i$ .

Нейро-нечіткі моделі, здатні ефективно функціонувати в умовах обмеженої інформації про об'єкт керування або інформації лише якісного характеру та можуть бути реалізовані кількома способами.

Перший підхід в реалізації нейро-нечітких моделей [1] розглядає механізм навчання штучної нейронної мережі (ANN), як препроцесор, який визначає правила нечіткого виведення (FIS). Як тільки параметри FIS визначаються, ANN починає роботу в звичайному режимі. Функції належності зазвичай апроксимуються нейронною мережею з навчальних даних.

Інший підхід у реалізації нейро-нечітких моделей – це паралельна модель [1, 2], в якій нейронна мережа допомагає нечіткій системі визначити потрібні параметри, особливо якщо вхідні змінні системи не можуть бути виміряні безпосередньо. Навчання відбувається тільки в нейронній мережі, а нечітка система залишається незмінною. В паралельній нейро-нечіткій моделі вхідні дані подаються на нейронну мережу, а вихід з нейронної мережі додатково обробляється за допомогою нечіткої системи логічного виведення.

Найбільш поширеними є інтегровані моделі, в яких навчальний алгоритм нейронної мережі використовується для визначення параметрів системи нечіткого виведення. Нечітка система виведення і відповідні функції належності базуються на апріорних знаннях системи. З іншого боку, механізм навчання нейронної мережі не залежить від апріорної інформації, а є стандартним для обраної архітектури ШНМ.

Градiєнтні методи, які можна використовувати для налаштування, як відомо, працюють швидко тільки при малій кількості параметрів, що настроюються та не гарантують визначення глобального екстремуму. Вони ідеальні для застосування в унімодальних задачах. В [4] розглянуто синтез нечіткого моделі на основі генетичного алгоритму. Для його успішної роботи не має значення форма поверхні відгуку і число визначених параметрів.

Генетичний алгоритм при вирішенні задачі відшукування екстремуму не вимагає обчислення похідних від нелінійних функцій. Разом з тим, етап налаштування параметрів адаптивних нечітких моделей, як правило, є багатоекстремальною задачею оптимізації, а генетичні алгоритми не завжди забезпечують знаходження глобального екстремуму.

Недоліки нечітких та нейромережових методів:

1. Конструкція майже всіх нейроструктур і їх навчання досить ускладнена через наявність кількох нейромереж і нетривіальну послідовність процедур навчання єдиної нейромережі.

2. Базовими блоками багатьох методів нейроідентифікації є емпіричні моделі.

Одним із шляхів вирішення проблем синтезу інтелектуальних ідентифікаторів є розробка нових і розвиток існуючих методів. Перспективним є підхід, заснований на сумісному використанні штучних нейронних мереж і нечітких моделей [5]. Використання нечітких моделей є найбільш ефективним однопараметричними SISO - об'єктами (single-input-single-output)

Перший підхід в реалізації нейро-нечітких моделей розглядає механізм навчання штучної нейронної мережі (ANN), як препроцесор, який визначає правила нечіткого виведення (FIS). Як тільки параметри FIS визначаються, ANN починає роботу в звичайному режимі. Функції належності зазвичай апроксимуються нейронною мережею з навчальних даних.

Інший підхід у реалізації нейро-нечітких моделей – це паралельна модель, в якій нейронна мережа допомагає нечіткій системі визначити потрібні параметри, особливо якщо вхідні змінні системи не можуть бути виміряні безпосередньо. Навчання відбувається тільки в нейронній мережі, а нечітка система залишається незмінною. В паралельній нейро-нечіткій моделі вхідні дані подаються на нейронну мережу, а вихід з нейронної мережі додатково обробляється за допомогою нечіткої системи логічного виведення.

Найбільш поширеними є інтегровані моделі, в яких навчальний алгоритм нейронної мережі використовується для визначення параметрів системи нечіткого виведення. Нечітка система виведення і відповідні функції належності базуються на апріорних знаннях системи. З іншого боку, механізм навчання нейронної мережі не залежить від апріорної інформації, а є стандартним для обраної архітектури ШНМ.

Як правило в якості нечітких моделей вибираються моделі Мамдані або Сугено. Нечіткі системи типу Сугено є високопродуктивними, але часто вимагають тривалих, складних процедур навчання. Нечіткі системи типу Мамдані використовують більш швидкі евристичні методи, але з втратою в продуктивності [3, 4]. Нейронечіткі моделі при вирішенні завдань синтезу систем автоматичного керування залишають не в повному обсязі вирішеними ряд проблем, пов'язаних з методологією аналізу і синтезу розглянутих систем, однак вони досить наочні і зручні в практичній реалізації. В нашому випадку при максимальній швидкості конвеєру 6 м/с та відстані 180м від датчиків входної ідентифікації до ванн обробки дефектів (поз.8 на рис 1.3) на обчислювання є 30с, чого цілком достатньо для обробки зображень.

Завдяки доступним методам оптичної обробки зображень, що присутні у відкритих бібліотеках OpenCV на нишній час в потенційному арсеналі дуже велика кількість алгоритмів вирішення завдання проекту. В [1,2,4] представлено рішення у вигляді нечіткого класифікатора, який за ознакою-кольором та певною кількістю пікселів на зображенні дозованого об'єму розчину, робить висновки про кількість присутності того чи іншого компоненту в розчині.

Цей підхід буде використано в роботі з огляду на наявність інформації про товщини дефектів в залежності від кольору (табл.1.1, 1.2).

### 1.3 Прийняті методи машинного навчання

На сьогодні використовуються три основні методи машинного

навчання.

### 1) Навчання з вчителем.

Навчання з вчителем, також відоме як кероване машинне навчання, визначається використанням позначених наборів даних для навчання алгоритмів класифікації даних або точного прогнозування результатів. Коли вхідні дані надходять до моделі, яка коригує свої ваги, поки не буде впоряджена належним чином. Є надзвичайно ефективним при використанні у певних обставинах.

Методи, які використовуються в керованому навчанні, включають нейронні мережі, наївну байєсівську регресію, лінійну регресію, логістичну регресію, тощо.

Навчання з вчителем будує модель, яка робить оцінки на основі доказів за наявності невизначеності. Алгоритм навчання під наглядом використовує відомий набір вхідних даних і відомі відповіді на дані (вихід) і навчає модель генерувати адекватні оцінки для відповіді на нові дані. Навчання з вчителем зазвичай використовується, якщо є заздалегідь відомі дані для результату, який ви намагаєтесь отримати.

Під час навчання з учителем алгоритму машинного навчання надається невеликий набір навчальних даних до роботи. Цей навчальний набір даних є меншою частиною більшого набору даних і служить для того, щоб дати алгоритму базове уявлення про проблему, рішення та точки даних, з якими потрібно працювати. Набір даних для навчання дуже схожий на остаточний набір даних за своїми характеристиками і надає алгоритму розмічені параметри, необхідні рішення задачі.

Потім алгоритм встановлює причинно-наслідковий зв'язок між змінними набору даних, будує відносини між заданими параметрами. Наприкінці навчання алгоритм отримує уявлення про продукційний зв'язок між введенням та висновком. Потім це рішення розгортається для використання з остаточним набором даних, з якого воно навчається так само, як і набір даних для навчання. Цей алгоритм застосовується в даній роботі.

## 2) Навчання без вчителя.

Перевага неконтрольованого машинного навчання: можливо працювати з немаркованими даними. Це означає, що людська праця не потрібна для того, щоб зробити набір даних машиночитаним, що дозволяє програмі працювати з набагато більшими наборами даних.

Навчання без вчителя знаходить приховані шаблони або внутрішні структури в даних і використовується, щоб зробити висновки з наборів даних, що складаються з вхідних даних без позначених відповідей. Найпоширенішою технікою навчання без вчителя є кластеризація, що використовується в роботі. Вона використовується для дослідницького аналізу даних, щоб знайти приховані закономірності або групи в даних. Програми для кластерного аналізу включають аналіз послідовності генів, розпізнавання об'єктів.

## 3) Навчання із підкріпленням.

Навчання з підкріпленням є проміжним варіантом між навчанням з вчителем і навчанням без вчителя. Під час навчання потрібен менший набір даних з мітками, щоб керувати класифікацією та виділенням ознак із більшого набору даних без міток. Такий тип навчання обходить нестачу достатньої кількості позначених даних для контрольованого навчання.

Алгоритми глибокого навчання можна розглядати як математичну еволюцію алгоритмів машинного навчання. Останнім часом ця галузь привертає багато уваги, бо останні розробки сягли неможливих раніше результатів. Майже усі останні досягнення в галузі штучного інтелекту за останні 12 років є результатом глибокого навчання.

Методи зменшення розмірності включають зменшення кількості вхідних ознак, змінних або атрибутів за збереження якомога більше інформативного набору даних. Продуктивність алгоритмів машинного навчання може знижуватися за надто великої кількості вхідних змінних. Більша кількість ознак збільшує шанс перенавчання моделі, що загрожує неякісним результатом. Зменшення розмірності відноситься до техніки

редукції розмірності набору ознак даних.

#### 1.4 Постановка задачі дослідження

Метою кваліфікаційної роботи є розробка системи інтелектуальної ідентифікації дефектів плоских поверхонь на прикладі поверхні сталевого прокату, з використанням нечіткого та нейромережевого підходів.

Для досягнення поставленої мети необхідно виконати наступні завдання:

- синтез нейронечіткої мережевої моделі ідентифікації дефектів поверхні сталевого прокату;

- імітаційне моделювання та тестовий експеримент роботи системи інтелектуальної ідентифікації дефектів поверхні сталевого прокату;

- удосконалення методу оцінювання якості вихідної продукції та функціонування ділянок технологічного процесу, який на відміну від існуючих використовує кластеризацію залишків дефектів поверхні прокату на виході процесу.

Досягнення поставленої мети включає вирішення наступних завдань:

- розробка інтелектуальної моделі ідентифікації стану РР та температурного завдання;

- розробка методів та алгоритмів інтелектуального регулювання температури робочого розчину з метою підтримання оптимального рівня його активності;

- імітаційне моделювання та експериментальні дослідження режимів роботи інтелектуальної системи регулювання температури робочого розчину.

Створювані системи ідентифікації щоб були ефективними повинні з одного боку, повно відображати властивості досліджуваного об'єкта, а з іншого – бути зручними для реалізації максимально простих алгоритмів. Слід зазначити, що найбільш доцільним для виконання завдання є використання

нейромережевої моделі SISO – об'єктами (single -input-single-output).

## 2 МАТЕМАТИЧНИЙ АПАРАТ ПОБУДОВИ СИСТЕМИ

Завданням ТП є очиснення поверхні сталевій смуги при підтримці заданої регламентом швидкості. Ідентифікація об'єктів «дефект» на вході та виході вирішується за допомогою нечіткого класифікатора дефектів за кольором та методами технологій комп'ютерного зору.

### 2.1 Використання нечітких і нейромережевих моделей в задачах ідентифікації дефектів на 2D поверхнях

Принцип функціонування нейро-нечіткої моделі в задачах ідентифікації може бути проілюстровано (рис. 2.1) на прикладі найбільш поширеної моделі ANFIS (Adaptive-Network-Based Fuzzy Inference System). ANFIS - адаптивна мережа нечіткого виведення реалізує нечітку систему Такагі–Сугено і являє собою п'ятишарову нейронну мережу прямого поширення сигналу. Вхідні керовані змінні моделі –  $x_1$  і  $x_2$  змінні (зазвичай це задане і поточне значення керованої змінної або їх неузгодженість), вихідна змінна  $y$  – керуючий вплив.




Рисунок 2.1 – Приклад структури ANFIS- мережі

Перший шар визначає нечіткі терми вхідних параметрів. Виходи вузлів цього шару є значеннями функції належності  $\mu_i(x_j)$  при конкретних

значеннях входів. Другий неадаптивний шар визначає посилення нечітких правил. Кожен вузол цього шару відповідає одному нечіткому правилу. Вузол другого шару з'єднаний з тими вузлами першого шару, які формують передумови відповідного правила. Виходами вузла  $\omega_i$  є ступінь виконання правила, яка розраховується як перемноження вхідних сигналів. Третій неадаптивний шар здійснює нормалізацію ступенів виконання правил:  $\bar{\omega}_i = \omega_i (\sum \omega_i)^{-1}$ . Неадаптивні вузли цього шару розраховують відносну вагу виконання нечіткого правила. Четвертий шар визначає внесок кожного нечіткого правила в вихід мережі: кожний вузол шару розраховує внесок нечіткого правила  $y_i$  в вихід мережі. П'ятий шар формує керуючий сигнал  $y = \sum y_i$ .

Вибір нейро-нечітких моделей здійснюється в залежності від класу вирішуваних задач і для інтелектуального керування найбільше застосування отримали моделі ANFIS. Структура ANFIS гарантує, що кожен лінгвістичний термін представлений тільки однією нечіткою множиною. Процедура навчання з ANFIS не має обмежень на модифікацію функцій належності. Через високу гнучкість адаптивних мереж ANFIS може мати безліч варіантів виконання і реалізації алгоритмів в системах керування.

В якості критеріїв оцінки «інтелектуальності» АСК приймаються: час навчання, онлайн адаптивність, досяжність заданого рівня помилок і вартість обчислень. За серіями вимірювань і аналітичними даними попередньо була проведена стандартизація значень змінних, що полягає в центруванні і нормуванні вхідних  $\hat{x}$  і вихідної  $y$  змінних:

$$\bar{x}_{jk} = \frac{x_{jk} - m_{x_j}}{\sigma_{x_j}}, \quad \bar{y}_k = \frac{y_k - m_y}{\sigma_y}, \quad j = \overline{1,3}, \quad k = \overline{1,600}, \quad (2.1)$$

де  $m_{x_j}$  – середнє вибірки  $x_{jk}$ ,  $k = \overline{1,600}$ ;

$m_y$  – середнє вибірки  $y_k$ ,  $k = \overline{1,600}$ ;

$\sigma_{x_j}$ ,  $\sigma_y$  – дисперсії вибірок  $x_{jk}$  і  $y_k$  відповідно.

Вектор узагальненого сигналу, що надходить на вхід моделі, враховує перешкоди вимірювань функцією  $\xi(k)$ :

$$y(k) = f(x(k)) + \xi(k). \quad (2.2)$$

Апроксимація нелінійності  $f(\bullet)$  радіально-базисними функціями:

$$\Phi_i(x) = \exp\left\{-\frac{\|x - \varphi_i\|^2}{\delta_i^2}\right\}, \quad (2.3)$$

де  $\varphi_i, \delta_i$  – центри та радіуси базисних функцій;  $\|\cdot\|$  – евклидова норма відповідно, призводить до нейромережевої моделі:

$$\hat{y}(k) = w_0 + \sum_{i=1}^N w_i \Phi_i(x), \quad (2.4)$$

де  $w_i$  – вектори вагових коефіцієнтів,  $i = \overline{1, N}$ .

При вирішенні задач ідентифікації при застосуванні ШНМ, процес побудови моделі розбивається на два етапи – визначення структури мережі і налаштування (навчання) її параметрів. Загальний вид структури наведено на рис.2.2.




Рисунок 2.2 – Структура радіально-базисної мережі

Зміна структури мережі здійснюється її поступовим ускладненням шляхом додавання нових нейронів, що проводиться кожного разу, коли при появі чергового вхідного сигналу виникає помилка ідентифікації  $e = y - \hat{y}$ , яка перевищує допустиму (для визначених вище параметрів процесу травління).

Навчання (параметрична ідентифікація) полягає у визначенні параметрів мережі  $\varphi_i, \delta_i, w_i$  і зводиться до мінімізації квадратичного функціоналу помилки:

$$J(k) = \|\varepsilon(k)\|^2 = \|y^*(k) - \hat{y}(k)\|^2, \quad e(k) = (y(k) - \hat{y}(k))^2. \quad (2.5)$$

Для налаштування параметрів мережі використовувався рекурентний алгоритм методу найменших квадратів (РМНК) з експоненціальним зважуванням інформації. Після навчання мережа використовується для ідентифікації параметрів ТР.

Для вирішення цієї задачі застосовано апарат RB – функцій і навчання моделі «з учителем» на вибірці вимірювань.

## 2.2 Нечіткий класифікатор дефектів поверхні сталевого прокату

Оцінка товщини дефекту  $\delta_n = [D_n - c_n; D_n + c_n]$  належить нечіткому LR-інтервалу та залежить від величини вимірюваного параметру – його кольору  $\delta_n(RGB)$ . В [2] були формалізовані логічні правила керування температурою та концентрацією ТР при травлінні систематичних дефектів у вигляді смуг окалини різної товщини і відтінків сірого кольору по краях рулону, і смуги оксидних плівок по його центру.

Ідентифікацію відтінку несистемних дефектів (НД) з метою скорочення часу обробки також запропоновано здійснювати за обчислюваною за формулою (2.7) компонентою яскравості  $Y$  – таблиця 2.5.

Для обліку дефектів запропоновано здійснювати підрахунок пікселів методом `ndimage.measurement` з бібліотеки `OpenCV`. Формулу перерахунку кольорного атрибута пікселів за компонентою яскравості наведено в [3]:

$$Y = 0.299R + 0.587G + 0.114B, \quad (2.6)$$

де  $Y$  - яскравість в відтінках сірого кольору;  $R, G, B$  - колірні діапазони  $[0 \div 255]$ .

Таблиця 2.1 – Колірний класифікатор товщин несистемних дефектів

	$X_m$ = Колір дефекту	$\delta_n$	$Y$	$Y^m$
1	Матовий алюміній	0,1	$227 \div 2$	229
2	Блідо-голубий	$5 \div 1$	$218 \div 2$	223
3	Світло-сірий	$13 \div$	$200 \div 2$	209
4	Сірий	$14 \div$	$189 \div 2$	198
5	Темно- сірий	$24 \div$	$137 \div 1$	142
6	Темно-сірий	$38 \div$	$45 \div 2$	67
7	Майже чорний	$34 \div$	$3 \div 39$	21

Локалізований за початковими координатами  $(x, y)$  несистемний дефект можна нечітко описати за допомогою функції належності  $\pi_n(X_m)$  – з областю значень на інтервалі  $[0, 1]$ . Функція  $\pi_n(X_m)$  визначає ступінь можливості віднесення  $m$  – го дефекту до  $n$  – го класу за значенням ознаки, що характеризує закономірності прояву значень параметра – товщини дефекту  $\delta_n$ , що лежить в нечіткому LR-інтервалі  $\delta_n = [D_n - c_n; D_n + c_n]$  в залежності від оцінки кольору  $X_m$  дефекту [3].

В [4] представлено ТП з оптичною ідентифікацією дефектів. Вхідна ідентифікація дефектів (координати  $(x, y)$  та колірні RGB-оцінки) дає можливість нечітко визначити величини завдання тиску подачі ТР  $P_t^* = f(\delta_n)$  до форсунок попереднього зрошення дефектів на дефектні області сталевій смуги. Тому точність та оперативність ідентифікації  $\delta_n$  становить важливу задачу в ТП.

На цей час для оперативних вимірювань  $\delta_n$  користуються або класичними громіздкими математичними моделями [5], що суттєво збільшує

час оцінки, або високочастотними індукційними пристроями [6]. Проблема оперативних вимірювань  $\delta_n$  високочастотними індукційними методами полягає в тому, що застосування ультразвукових сенсорів може призвести до непрогнозованої появи центрів кристалоутворення  $n$ -гідратів сульфату залігідратів. Зайва ж присутність мультигідратів в розчинах травильних ванн БТА прискорює процес старіння ТР, знижує його якість, тим самим зменшуючи ефективність ТП і порушуючи його регламент і режим.

Пропонований КТЗ, прототип якого наведено в [1], імплементується у ділянку ідентифікації дефектів в наступному составі:

– цифровий фоторегістратор-аналізатор на 6 млн.пикселей FESTO SBOC-Q (з матрицею 1280 x 1024 пікселів, швидкість зйомки 240 кадрів / с ) з каналом передачі даних (USB, RS-485, HDMI), що формує графічні файли зображень маркованих ділянок прокату з дефектами поверхні на вході/виході з ТП в форматі .JPG (наведено на рис.2.3).

Система комп'ютерного розпізнавання зображень за RGB-кодом обробляє переданий файл підсумковуючи пікселя одного класу за ознакою кольору [4, 6, 7]. Вона призначена для автоматичного аналізу зображень, класифікації кожного пікселя зображення на 7 об'єктів і підрахунку за займаною площею кожного з дефектів.

На рисунку 2.8 представлені: зліва – зображення оригіналів поверхні дефекту (а, в, д, ж, к), відповідно справа – зображення дефектів після обробки (б, г, е, з, л).




Рисунок 2.3 – Дефекти поверхні прокату (а) – на вході в ТП, (б) на – виході

Кожному зображенню, що характеризує стан поверхні прокату з

наявністю певних кількостей  $k$ -го дефекту, відповідає певна кількісна оцінка  $\Delta V_k$  наявності об'єму  $k$ -го дефекту. Ця оцінка визначається площею відповідного фрагменту зображення, що підраховується за кількістю пікселів (для інтервалу RGB-коду кольору), множеною на оцінку його товщини:

$$\Delta V_k = S_k \times B_k(Y(RGB)) \times \delta_k, \quad (2.7)$$

де  $B_k$  – індикативна булева змінна зі значеннями 0 або 1, що описує належність пікселя  $k$ -го кластеру кольору відповідно LR-інтервалу RGB-коду кольору або його оцінки  $Y$ ;

$S_k$  – число пікселів, що потрапляють в  $k$ -й кластер кольору, яке визначається результатами аналізу файлу зображення системою-класифікатором

$\delta_k$  – оцінка товщини  $k$ -го дефекту, сформована нечітким класифікатором (або РБМ, побудованим на його базі).

Система може послідовно аналізувати до 256 зображень, запам'ятовувати їх в окремій таблиці і представляти накопичені дані (якщо їх більше 5) у формі графіків дисперсії. Система має можливість налаштування еталонів кольорів, навчається у реальному часі та є відкритою: в процесі навчання доповнюється множинами синглетонів та розширює базу правил логічного висновку, що визначає побудову нечіткої продукційної моделі [8]:

$$Y_k \rightarrow D_k, \quad (2.8)$$

на базі початково зформованої множини логічних правил [69] виду  $R_i$ : ЯКЩО ( $Y=y_i$ ) ТО ( $D=\delta_i$ ),  $i=1,2,\dots,n$ .

Налаштування цієї моделі здійснюється з використанням методу нечіткої кластеризації (Fuzzy Clustering Method) [70]. Витяг даних може відбуватися як безпосередньо в ході ТП, так і в окремих лабораторних експериментах. В обох випадках є обов'язковими одночасні тестові серії вимірювань концентрації компонентів розчину еталонними приладами і

методами: титрування, зважування сухого залишку та інші, – з подальшою обробкою набраних статистик.

З урахуванням адитивних змін значень  $D$  і  $Y$ , кожен рядок довільних в загальному випадку вимірювань можна представити як кластер із своїм центром. Формування та налаштування (конфігурація моделі) класифікатора проводиться при наступних припущеннях: дефект явно відноситься до  $k$ -го класу на основі кольору; відомі його площа з відносною точністю 1 піксель до 1080 (точність камери) і множина тестованих зразків. Точність вимірювання вхідного параметра дорівнює 0,005%, що дає можливість розрізняти зразки вимірів між кластерами. Функція  $D_k(t) = f(Y_k(t))$  прийнята одновимірною та монотонною. Вимірювання проводяться через рівні проміжки часу. Налаштування класифікатора засновано на методі  $k$ -середніх для одновимірного випадку [6].

Число кластерів в кожній із серій  $L$ , що складається з  $N$  вимірів, визначають емпірично в залежності від частоти прояву і модальних значень вхідних і вихідних параметрів в серії вимірювань. Кожен елемент вибірки вимірювань входить до найближчого кластеру. Включення елементів до кластерів здійснюється на основі мінімуму декартової відстані.

При проведенні модельного експерименту, стохастичний емулятор вхідних даних медіана (центр)  $i$ -го кластера по вхідній координаті  $y$  визначається кумулятивно, з урахуванням всіх включених до кластера  $N$  елементів відповідно до формули:

$$m_{y_i}(t) = \frac{1}{N} \sum_{j=1}^{N_i} y_j(t), \quad i = 1, \dots, l. \quad (2.9)$$

Модельна серія з  $n$  «вимірювань» утворює один додатковий кластер. Максимально близький до  $y_j$  кластер з центром  $m_{y_i}$  визначається відповідно до формули (2.12):

$$\text{MIN}(d_{ij}) = \|m_{Y_j} - y_i\|, \quad j=1, \dots, l. \quad (2.10)$$

Подання  $D_i^*$  в околиці точки  $y_i = y_i \pm \delta_j$  може бути обчислено з використанням гаусової функції належності відповідно до формули:

$$D_i^*(y_i) = \frac{\sum_{j=1}^n D_j \cdot \exp\left[\frac{-(y_i - Y_j)^2}{2\delta_j^2}\right]}{\sum_{j=1}^n \exp\left[\frac{-(y_i - Y_j)^2}{2\delta_j^2}\right]} \quad (2.11)$$

де  $(y_i, D_i)$  – точки  $n$  результатів моделювання,  $\delta_j$  – налаштовувана величина функції належності  $j$ -го кластера, якої зазвичай привласнюють значення:

$$\delta_j = \frac{1}{3} \cdot \text{MIN} \|m_{Y_j} - y_j\|, \quad \forall y_j \in (m_{Y_j} - \varepsilon_j; m_{Y_j} + \varepsilon_j), \quad (2.12)$$

де  $\varepsilon$  – порог інтервалу довіри, в межах якого лежить центр кластера.

З огляду на нерівномірний розподіл центрів кластерів у вхідному просторі доцільно використовувати експоненціальні функції належності, що визначаються як:

$$\mu_{Y_i}(x) = \exp\left\{-\frac{(m_i - x)^2}{2\delta_i^2}\right\}, \quad i=1, \dots, k. \quad (2.13)$$

Всередині кластера функція належності реалізується за допомогою Гаусових функцій FCM-методом (Fuzzy Classifier Means), при цьому  $Y_i$  і  $Y_{i-1}$  приймаються як центри сусідніх класів [7]. Поточне значення  $Y(t) = x$ , що отримується в ході виконання ТП, відносять до  $i$ -го класу за критерієм мінімуму Евклідової відстані від оцінюваного об'єкта до центру  $i$ -го кластера.

Інтервал  $Y_i \leq y_i \leq Y_{i+1}$  визначає межі кластера за входом.

### 2.3 Технології комп'ютерного зору

OpenCV (Open Source Computer Vision) - це бібліотека для використання методів технології комп'ютерного зору в реальному часі.

Працюючи із статичним зображенням в реальному часі необхідно максимізувати швидкість обробки зображень для отримання оперативної оцінки присутніх дефектів. Фрагмент коду підрахунку кількості пікселів одного кольору наведено нижче.

```

from PIL import Image
im = Image.open('./ss_mm_hh_dd_ln_defects.png').getcolors()
im.sort(key=lambda k: (k[0]), reverse=True)
print('Top 5 colors: {}'.format((im[:5])))

# View non-background colors
color_values = []
for color in im[1:5]:
    color_values.append(color[1])
arr = np.asarray(color[1]).reshape(1,1,4).astype(np.uint8)
plt.imshow(arr)
plt.show() # get top 4 frequent colors as
green,blue,pink,orange

# Create a dict of color names and their corresponding rgba
values
color_dict = {}
for color_name,color_val in zip(['green','blue','pink','orange'],color_values):
    color_dict[color_name] = color_val

# Make use of ndimage.measurement.labels from scipy
# to get the number of distinct connected features that

```

```

satisfy a given threshold
    for color_name,color_val in color_dict.items():
        b = ((img[:, :, 0] ==color_val[0]) * (img[:, :, 1]
==color_val[1]) * (img[:, :, 2] ==color_val[2]))*1
        labeled_array, num_features =
scipy.ndimage.measurements.label(b.astype('Int8'))
        print('Color:{}'.format(color_name,num_features))

```

### 3 ІНТЕЛЕКТУАЛЬНА ІДЕНТИФІКАЦІЯ ТОВЩИННИ ДЕФЕКТІВ

Існує величезна кількість інструментів для проведення математичних досліджень, наприклад, Simulink Matlab – середовище програмування експериментальних досліджень, емуляцій ТП, яке надає можливість відтворити практично будь-який процес. Для побудови прототипу нейронної мережі використано пакет NeuroPh Studio.

#### 3.1 Налаштування моделі


В рамках роботи на базі нечіткого класифікатора, що визначає товщину дефекту в залежності від його колірної оцінки яскравості в «сірому», була побудована проста радіально-базисна мережа  $\delta_n(x, y, Y)$  структурою 1-28-1. В процесі моделювання проводилися проби мереж різних типів та структур. Як підтверджує практика SISO-моделі найкраще втілюються в РБМ

Вибір архітектури РБМ здійснено за процедурою дискримінації [9], при визначенні кращої структури мережі здійснювався наступний алгоритм:


- обираються  $N$  нейромережових моделей;
- задається максимальна кількість циклів навчання мережі  $k$ ;
- задається період дискримінації  $m < k$ ;
- кожні  $m$  циклів навчання перевіряються умови, пов'язані з оцінкою доцільності виключення деяких мереж з розгляду і видаляються всі ШНМ, для яких ці умови виконуються;
- алгоритм зупиняється при досягненні заданої максимальної кількості циклів навчання  $k$ .

У якості активаційних функцій РБМ використовувалися: лінійні вхідні функції зваженої суми в 1-м шарі, сигмоїдні активаційні функції в 2-му шарі, і лінійна зваженої суми в 3-м вихідному шарі. Навчання РБМ проходило в пакеті NeuroPhStudio при заданому порозі помилки  $e^2 = 0.01$  за алгоритмом зворотнього поширення помилки.

### 3.2 Результати тестового експерименту



а) Зображення оригіналу дефекту  $(x, y, Y)$



б) Ідентифіковано мережею  $\delta_n(x, y, Y)$

Рисунок 3.1 – Подання ідентифікованої поверхні дефекту

## 4 ЗАСТОСУВАННЯ СИСТЕМИ ІДЕНТИФІКАЦІЇ ДЕФЕКТІВ В ТЕХНОЛОГІЧНОМУ ПРОЦЕСІ

### 4.1. Критерії якості обробки поверхні

Одним із критеріїв контролю якості ТП є коефіцієнт чистоти поверхні, який використовує оцінки ідентифікації дефектів поверхні, і в загальному вигляді його можна представити:

$$q_e = \frac{\sum S_i^{Out} d_i}{\sum S_j^{In} d_j} \quad (4.1)$$

де  $S_i^{Out}$  – площа дефектів  $i$ -го класу з товщиною  $d_i$  на виході з ТП;

$S_j^{In}$  – площа дефектів  $i$ -го класу з товщиною  $d_j$  на вході в ТП.

Перевищення  $q_e$  заданого регламентом ТП значення  $q_r$  протягом певного періоду часу зазначеного вікна спостереження ( $t(k); t(k + 10)$ ) свідчить про необхідність зміни правил навчання та параметрів ідентифікаційної моделі.

Також можна використати оперативну оцінку вигляду:

$e_{def}$  – сумарна помилка травління усіх дефектів класів  $e_{grc}$ ,  $e_{dot}$ ,  $e_{col}$ , що враховує взаємовплив всіх факторів ТП, обчислювана за формулою:

$$e_{def} = e_{grc} + e_{dot} + e_{col} = \frac{1}{S} \sum_{i=1}^N S_i \cdot \frac{\|Y(RGB)_{et} - Y(RGB)_i\|}{\|Y(RGB)_{et}\|}, \quad (4.2)$$

де  $e_{grc}$  – помилка травління жорстких оксидів сірої гами по краях рулону;

$e_{dot}$  – помилка травління несистемних точкових дефектів;

$e_{col}$  – помилка травління кольорових оксидних плівок по центру рулону;

$S$  – загальна площа смуги, протравлена в період  $(t+1) - (t)$ ;

$s_i$  – сумарна площа дефектів з відхиленнями  $RGB_i$  від колірного еталона  $RGB_{et}$ .

#### 4.2. Оцінювання якості роботи технологічного процесу

Помилки  $e_{grc}$ ,  $e_{dot}$ ,  $e_{col}$ , оцінювані в тимчасових вікнах і представляють собою залишки відхилень в контурах керування ТП, адекватно відображають швидкість реакції ОК на дії АСК і служать інформацією для оперативного контролю якості.

Перевищення загальної помилки  $e_{def}$  регламентованої величини  $E_{def}$ , за період більший встановленого часового вікна, свідчить про розрегулювання в ТП. При відсутності додаткової інформації про вихід з режиму в якомусь з контурів керування здійснюється аналіз складових  $e_{def}$ .

Якщо  $e_{grc} > E_{grc}$  це може свідчити про: недогрів ТР, невідповідність концентрації ТР необхідному рівню, невірне формування завдань тиску в форсунках, розташованих по краях рулону прокату.

Якщо  $e_{col} > E_{col}$  це свідчить про: недогрів ТР або невідповідність концентрації ТР завданню., невірне формування завдань тиску в форсунках, розташованих по краях рулону прокату.

Якщо  $e_{dot} > E_{dot}$  – невірне формування завдань тиску попереднього зрошення. В перспективі множину цих ЛПК доцільно систематизувати в вигляді ШНМ.

На підставі аналізу залишків нейросупервізор виявляє нештатні ситуації, стани системи близькі до аварійних, і формує сигнали, які ініціюють контури керування; якщо залишки перевищують заданий рівень протягом певного періоду часу – коригує еталонні моделі ідентифікації, що формують поточні завдання. Доцільно зформувати інтегральний індекс якості –  $q_I$  що буде індикативно інформувати про відхилення в контурах керування при привищенні регламентного показника  $q_R$  – допустимих забруднень поверхні прокату після травління. У випадку коли  $q_I \geq q_R$  – має проводитися ретельний

аналіз залишкових дефектів поверхні прокату за класами по оцінках  $e_{grc}$ ,  $e_{dot}$ ,  $e_{col}$ , а також середніх значень і відхилень помилок для діагностики якості керування в різних контурах.

## ВИСНОВКИ

Метою роботи є розробка системи інтелектуальної ідентифікації дефектів плоских поверхонь на прикладі поверхні сталевго прокатуї, з використанням нечіткого та нейромережевого підходів.

Для досягнення поставленої мети були вирішено ряд теоретичних і практичних завдань, в саме:

- обзор літератури та аналіз сучасних сучасних рішень;
- синтез нейронечіткої мережевої моделі ідентифікації дефектів поверхні сталевго прокату на основі зформованого нечіткого класифікатора;
- імітаційне моделювання та тестовий експеримент роботи системи інтелектуальної ідентифікації дефектів поверхні сталевго прокату;
- удосконалено метод оцінювання якості вихідної продукції та функціонування ділянок технологічного процесу, який на відміну від існуючих використовує кластеризацію залишків дефектів поверхні прокату на виході процесу та оцінки системи інтелектуальної ідентифікації дефектів плоских поверхонь.

Все це підтверджує працездатність запропонованого методу оцінювання якості вихідної продукції та функціонування ділянок технологічного процесу

## ПЕРЕЛІК ДЖЕРЕЛ ПОСИЛАННЯ

1. Ilyunin O.O., Khodak M.V., Yurchenko O.V., Sapeha O.A. Fuzzy estimation procedure of the concentration of the components of a sulfuric acid pickling solution. ISSN 2078-0625 (online). Інтегровані технології та енергозбереження. Щоквартальний науково-практичний журнал. – Харків: НТУ «ХПІ», 2022. – № 3, с.63-75. Фахове видання. Доступно за адресою: [https://docs.google.com/document/d/1VivXA87odmmdxCISdkXJG\\_Jpc1DRjSvF/edit?usp=share\\_link&oid=118443346938890580156&rtpof=true&sd=true](https://docs.google.com/document/d/1VivXA87odmmdxCISdkXJG_Jpc1DRjSvF/edit?usp=share_link&oid=118443346938890580156&rtpof=true&sd=true)
2. О. Ілюнін, С. Удовенко, М. Ходак, О. Юрченко, О. Сапега, Інтелектуальна ідентифікація дефектів металопрокату з застосуванням технологій «комп'ютерного зору». Україна, Вінниця, конференція "Контроль і управління в складних системах", 2022-11-15, (Vinnytsia), КУСС-2022. URL: <<https://conferences.vntu.edu.ua/index.php/mccs/mccs22/index>>.
3. Руденко О. Г. Искусственные нейронные сети: архитектуры, обучение, применения / О. Г. Руденко, Е. В. Бодянский. – Харьков: ТЕЛТЕХ, 2004. – 370 с.
4. O.Bezsonov, O.Ilyunin, A.Khusanov, O.Rudenko, O.Sotnikov. Intelligent Identification System of the Process Liquid Solutions Composition. COLINS-2022: 6th International Conference on Computational Linguistics and Intelligent Systems, May 12–13, 2022, Gliwice, Poland URL: <<https://ceur-ws.org/Vol-3171/paper69.pdf>>
5. Хайкин С. Нейронные сети: полный курс. 2-е издание: пер. с англ. М.: Издательский дом «Вильямс», 2006. 1104 с.
6. Ягер Р.Р. (ред.). Нечеткие множества и теория возможностей. Последние достижения: пер. с англ В.Б. Кузьмина. М: Радио и связь, 1986. 408 с.
7. Zadeh Lotfi A. (Ed.). Computing with Words in Information / Intelligent Systems 2. Heidelberg: Physyca – Verlag, 1999. 610 p. DOI 10.1007/978-3-7908-

1872-7.

8. Babuska R. Fuzzy Modeling for Control. Norwell, MA: Kluwer, 1998.
9. Intelligent Systems'2014. (Eds. Filev D. et al.). Proc. of the 7th IEEE International Conf. Intelligent Systems IS'2014, September 24-26, 2014, Warsaw, Poland. Volume 2: Tools, Architectures, Systems, Applications. Springer, 2014. 907 p. DOI 10.1007/978-3-319-11310-4.
10. US Patent № 6419756. Process and equipment for a metal strip pickling. B08B 1/02; B08B 7/04. Wielfried Schlechter ; assignee: Siemens Aktiengesellschaft (Munich, DE) ; filing date 01.06.2000 ; publication date: 16.07.2002, 6 p. <https://www.freepatentsonline.com/6419756.html>
11. Пат. 104710 УКРАЇНА, МПК (2014.01) C23G 3/00, B08B 1/02 (2006.01), C23G 7/08 (2006.01), B08B 3/08 (2006.01), C23F 1/08 (2006.01), B08B 13/00. Пристрій для безперервного травлення прокату листової вуглецевої сталі. Арсеньєва О.П., Ілюнін О.О., Перевертайленко О.Ю., Подпружников П.М., Селяков О.М., Тимофєєв В.А.; заявник та власник Харківський національний університет радіоелектроніки. № у 2012 09428; заявл. 02.08.12; опубл. 25.02.2014, Бюл. № 4.
12. Нестеренко О. В., Савенко О. І., Фаловський О. О. Інтелектуальні системи підтримки прийняття рішень: навч. посібн./ за ред. П.І. Бідюка – Київ: Національна академія управління, 2016. – 188 с.
13. He Changlin, Li Yufen. A Survey of Intelligent Decision Support System. Advances in Engineering Research, volume 122: 7th International Conference on Applied Science, Engineering and Technology (ICASET 2017), Qingdao, China, 29–30 July 2017. 2017. P. 201–206.
14. Рассел С., Норвиг П. Искусственный интеллект: современный подход, 2-е изд/ пер. з англ. К.А. Птицын.: Вильямс, 2016. 1408 с.
15. 7 архитектур нейронных сетей для решения задач NLP. URL: <https://neurohive.io/ru/osnovy-data-science/7-arhitektur-nejronnyh-setej-nlp> (дата звернення: 04.11.2021).
16. Субботін С. О. Нейронні мережі: теорія та практика: навч. посіб. –

Житомир: Вид. О. О. Євенок, 2020. – 184 с.

17. Корабльов М.М. Інтелектуальна система підтримки прийняття клінічних рішень на основі мультиагентного підходу та міркувань по прецедентам // Сучасні інформаційні технології і системи: монографія / за заг. ред. В.С. Пономаренка. – Х.: ХНЕУ ім. С. Кузнеця, 2022. – С. 139-164.

18. Mykola Korablyov, Natalia Axak, Oleksandr Fomichov and Andrii Chuprina. Hybrid Neuro-Fuzzy Model with Immune Training for Recognition of Objects in an Image / Proceedings of the 9th International Conference "Information Control Systems & Technologies", Odessa, Ukraine, September 24–26, 2020. – pp. 267-281

19. Кораблев Н.М., Фомичев А.А., Соловьев Д.Н., Чуприна А.А. Гибридные модели принятия решений с использованием иммунного подхода // Информационные управляющие системы и технологии. Проблемы и решения: монография. Под науч. ред. проф. Вычужанина Владимира. – Одесса: Экология, 2019. – С. 100-116.

20. Korablyov, M., Axak, N., Soloviov, D. Hybrid evolutionary decision-making model based on neural network and immune approaches (2018 IEEE 13th International Scientific and Technical Conference on Computer Sciences and Information Technologies, CSIT 2018 – Proceedings 1,8526594, с. 378-381.)