

Міністерство освіти і науки України
Криворізький національний університет
Факультет інформаційних технологій
Кафедра автоматизації, комп'ютерних наук і технологій

КВАЛІФІКАЦІЙНА РОБОТА

на здобуття ступеню вищої освіти – магістр
за освітньо-професійною програмою
«Автоматизація, комп'ютерно-інтегровані технології та робототехніка»

зі спеціальності

174 – Автоматизація, комп'ютерно-інтегровані технології та робототехніка

тема роботи:

«Автоматизація процесу керування параметрами мікро-клімату при зберіганні борошна»

Виконав студент гр. АКІТР-22м. _____ Голуб Е.В.

Керівник _____ Харламенко В.Ю.

Нормоконтроль _____ Маринич І. А.

Завідувач кафедри _____ Рубан С. А.

Кривий Ріг – 2024

КРИВОРІЗЬКИЙ НАЦІОНАЛЬНИЙ УНІВЕРСИТЕТ**Факультет:** інформаційних технологій**Кафедра:** автоматизації, комп'ютерних наук і технологій**Ступінь вищої освіти:** Магістр**Спеціальність:** Автоматизація, комп'ютерно-інтегровані технології та робототехніка**ЗАТВЕРДЖУЮ**В.о. зав. кафедрою: доцент Рубан С.А.

« ____ » _____ 2024 р.

ЗАВДАННЯ**на кваліфікаційну роботу магістра**

студенту групи АКІТР-22м Голубу Едуарду

1. Тема роботи: «Автоматизація процесу керування параметрами мікро-клімату при зберіганні борошна»затверджено наказом по університету 595с від 04.07.2024р**2. Термін здачі завершеної роботи:** 1.12.24**3. Склад кваліфікаційної роботи:** Пояснювальна записка обсягом 80 с., презентація у Microsoft PowerPoint (слайдів) в електронному та друкованому вигляді**4. Консультанти кваліфікаційної роботи:**

Розділ 1-3

Харламенко В.Ю.

Нормоконтроль

доц. Маринич І. А.

5. Календарний план:

№	Етапи роботи	Термін виконання
1	<i>Вступ</i>	01.04.2024
2	<i>Аналіз підходів до підвищення ефективності процесу</i>	25.04.2024
3	<i>Моделювання системи</i>	15.05.2024
4	<i>Проектування системи</i>	12.07.2024
5	<i>Висновки</i>	08.10.2024
6	<i>Оформлення кваліфікаційної роботи</i>	20.11.2024
7	<i>Підготовка презентації та графічного матеріалу</i>	30.11.2024
8	<i>Підготовка доповіді до захисту</i>	06.12.2024

6. Дата видачі завдання: 28.06.24

Керівник _____ /Харламенко В.Ю. /

7. Запевнення: Я, Голуб Едуард Віталійович, запевняю, що ця кваліфікаційна робота виконана самостійно, не містить академічного плагіату, фабрикації, фальсифікації. Використання ідей, результатів і текстів інших авторів мають посилання на відповідне джерело.

Із чинним Положенням про академічну доброчесність Криворізького національного університету з метою запобігання та виявлення академічного плагіату в роботах здобувачів вищої освіти ознайомлений. Чітко усвідомлюю, що в разі виявлення у кваліфікаційній роботі умисних порушень робота не допускається до захисту або оцінюється незадовільно.

Студент _____ / Голуб Е.В./

АНОТАЦІЯ

Голуб Е.В. Автоматизація процесу керування параметрами мікро-клімату при зберіганні борошна.

Випускна магістерська робота на здобуття освітнього ступеня «магістр» за спеціальністю 174 – Автоматизація, комп'ютерно-інтегровані технології та робототехніка. – Криворізький національний університет, Кривий Ріг, 2024.

У магістерській роботі проведено дослідження, спрямоване на створення та впровадження інтелектуальної системи автоматизованого управління параметрами мікроклімату в процесі зберігання борошна.

У першому розділі проведено аналіз технологічного процесу зберігання борошна, який є складним через нелінійні взаємозв'язки між ключовими параметрами: температурою, вологістю повітря та вмістом вуглекислого газу. Визначено основні обмеження та можливості впровадження інтелектуальних систем управління, здатних забезпечити високий рівень точності та адаптивності.

Другий розділ присвячено використанню нейронних мереж у процесі зберігання борошна та обґрунтуванню вимог до системи. Описано архітектуру багат шарового перцептрона, що здатен вирішувати задачі прогнозування та регулювання кліматичних параметрів. Визначено критерії вибору архітектури нейронної мережі з урахуванням особливостей даних і обмежень виробничого середовища.

Третій розділ об'єднує процес підготовки даних, моделювання системи керування та її інтеграцію у виробниче середовище. Модель впроваджено у середовище MATLAB/Simulink із подальшою інтеграцією через OPC UA у TIA Portal. Розроблено панель оператора, яка дозволяє контролювати й регулювати параметри мікроклімату в автоматичному та ручному режимах. Проведено тестування системи на валідаційній вибірці, яке підтвердило її ефективність.

АВТОМАТИЗАЦІЯ, НЕЙРОННІ МЕРЕЖІ, ЗБЕРІГАННЯ БОРОШНА, КЛІМАТИЧНІ ПАРАМЕТРИ, АВТОМАТИЗОВАНЕ УПРАВЛІННЯ, OPC UA, SCADA, ПРОМИСЛОВЕ СЕРЕДОВИЩЕ.

ANNOTATION

Golub E.V. Automation of the process of controlling microclimate parameters during flour storage.

Master's thesis for the degree of Master of Science in speciality 174 - Automation, computer-integrated technologies and robotics - Kryvyi Rih National University, Kryvyi Rih, 2024.

In the master's thesis, a study was conducted aimed at creating and implementing an intelligent system for automated control of microclimate parameters during flour storage.

The first section analyses the technological process of flour storage, which is complex due to the nonlinear relationships between key parameters: temperature, humidity and carbon dioxide content. The main limitations and opportunities for implementing intelligent control systems capable of providing a high level of accuracy and adaptability are identified.

The second section is devoted to the use of neural networks in the process of flour storage and the justification of requirements for the system. The architecture of a multilayer perceptron is described, which is capable of solving the following tasks of forecasting and regulating climate parameters. The criteria for choosing a neural network architecture are defined, taking into account the characteristics of the data and the limitations of the production environment.

The third section combines the process of data preparation, modelling of the control system and its integration into the production environment. The model was implemented in the MATLAB/Simulink environment with further integration via OPC UA into the TIA Portal. An operator panel was developed that allows monitoring and adjusting microclimate parameters in automatic and manual modes. The system was tested on a validation sample, which confirmed its effectiveness.

AUTOMATION, NEURAL NETWORKS, FLOUR STORAGE, CLIMATE PARAMETERS, AUTOMATED CONTROL, OPC UA, SCADA, INDUSTRIAL ENVIRONMENT.

ЗМІСТ

ВСТУП.....	9
РОЗДІЛ 1 АНАЛІЗ ТЕХНОЛОГІЧНОГО ПРОЦЕСУ ТА МЕТОДІВ ЙОГО ОПТИМІЗАЦІЇ.....	12
1.1 Аналіз технічної схеми зберігання борошна.....	12
1.2 Взаємозв'язок параметрів керування мікрокліматом силоса для безтарного зберігання борошна.....	19
Висновки за розділом.....	27
РОЗДІЛ 2 ВИКОРИСТАННЯ НЕЙРОННИХ МЕРЕЖ У ПРОЦЕСІ ЗБЕРІГАННЯ БОРОШНА І ВИМОГИ ДО РОЗРОБЛЮВАНОЇ СИСТЕМИ...	28
2.1. Архітектури та типи нейронних мереж.....	28
2.2 Вимоги до реалізації системи на базі нейронних мереж.....	38
Висновки за розділом.....	42
РОЗДІЛ 3 ПРОГРАМНО-ТЕХНІЧНА РЕАЛІЗАЦІЯ СИСТЕМИ КЕРУВАННЯ ПРОЦЕСОМ.....	44
3.1 Відбір даних для навчання нейромережі.....	44
3.2 Алгоритм для навчання мережі та алгоритм роботи адаптивного керування системи.....	46
3.3 Програмна реалізація системи.....	50
Висновки за розділом.....	75
ВИСНОВКИ	76
СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ.....	78

ВСТУП

Актуальність. Визначається важливістю ефективного та безпечного зберігання харчових продуктів у сучасних умовах. Борошно є основним продуктом у харчовій промисловості, тому його якість безпосередньо впливає на безпеку кінцевого продукту і економічні показники підприємств.

Найбільші виклики при зберіганні борошна пов'язані з контролем кліматичних параметрів, таких як температура і вологість, адже коливання цих параметрів можуть призвести до псування борошна, втрати його поживних властивостей, а також до появи плісняви або шкідників. У традиційних системах контролю ці параметри регулюються вручну або за допомогою простих автоматизованих систем, що часто не враховують складні взаємозв'язки між факторами навколишнього середовища.

Застосування технологій штучного інтелекту, зокрема нейронних мереж, дозволяє суттєво покращити процес моніторингу та управління кліматичними умовами, забезпечуючи високу точність і адаптивність системи. Нейронні мережі можуть не лише аналізувати поточний стан середовища, але й прогнозувати майбутні зміни на основі зібраних даних, що дозволяє уникнути непередбачених коливань клімату і підтримувати оптимальні умови зберігання.

В умовах зростаючих вимог до якості продуктів харчування, а також у контексті енергозбереження, розробка систем автоматичного управління з використанням нейронних мереж є особливо актуальною. Вона дозволить не лише підвищити ефективність зберігання борошна, але й знизити витрати на енергоресурси та покращити економічні показники підприємств.

Мета і задачі дослідження. Метою даної роботи є створення та впровадження інноваційної автоматизованої системи управління кліматичними умовами (температура, вологість, вентиляція) у приміщеннях для зберігання борошна. Дана система базується на використанні нейронних

мереж, які дозволяють забезпечувати високий рівень адаптивності та точності в управлінні.

Основними завданнями дослідження є:

1. Підвищення ефективності зберігання борошна через автоматизований контроль ключових кліматичних параметрів, що мінімізує ризик псування продукції внаслідок несприятливих змін умов середовища.

2. Оптимізація енергоспоживання за рахунок впровадження адаптивних алгоритмів управління вентиляційними та охолоджувальними системами, які враховують як поточні кліматичні дані, так і прогнозовані зміни.

3. Гарантування стабільної якості борошна на всіх етапах зберігання шляхом точного налаштування мікроклімату, що виключає негативний вплив зовнішніх факторів.

4. Розробка прогнозної моделі на основі нейронних мереж для аналізу наявних даних та прогнозування можливих змін кліматичних умов. Така модель дозволить своєчасно реагувати на потенційні відхилення та підтримувати оптимальні умови зберігання.

5. Забезпечення економічної ефективності процесу зберігання шляхом зменшення витрат на енергоресурси і попередження втрат продукції через псування.

У результаті реалізації даної системи очікується значне підвищення точності та ефективності управління кліматичними умовами в сховищах для борошна, що сприятиме збереженню високої якості продукції, зменшенню витрат на її зберігання та підвищенню рентабельності підприємств.

Об'єкт дослідження. Об'єктом дослідження є процес зберігання борошна в спеціалізованих приміщеннях із регульованими кліматичними умовами.

Предмет дослідження. Предметом дослідження є методи автоматизованого управління кліматичними параметрами (температура, вологість, вентиляція) із застосуванням нейронних мереж для прогнозування та оптимізації умов зберігання.

Проблема дослідження. У магістерській роботі проблема полягає у складності забезпечення стабільних кліматичних умов (температура, вологість, вентиляція) для тривалого зберігання продукту. Зміна кліматичних параметрів може призводити до псування борошна, втрати якості, утворення плісняви, розмноження шкідників і погіршення поживних властивостей.

Традиційні методи контролю клімату, що базуються на ручному управлінні або простих автоматизованих системах, є недостатньо ефективними через низьку точність, нездатність враховувати складні взаємозв'язки між параметрами, а також відсутність прогнозування можливих змін умов. Нераціональне використання ресурсів таких систем призводить до надмірного енергоспоживання та зростання витрат.

Пропонується розробка адаптивної системи кліматичного контролю на основі нейронних мереж, здатної враховувати динамічні зміни умов, точно прогнозувати їх розвиток і автоматично регулювати параметри зберігання для забезпечення стабільної якості борошна та економії енергоресурсів.

РОЗДІЛ 1

АНАЛІЗ ТЕХНОЛОГІЧНОГО ПРОЦЕСУ ТА МЕТОДІВ ЙОГО ОПТИМІЗАЦІЇ

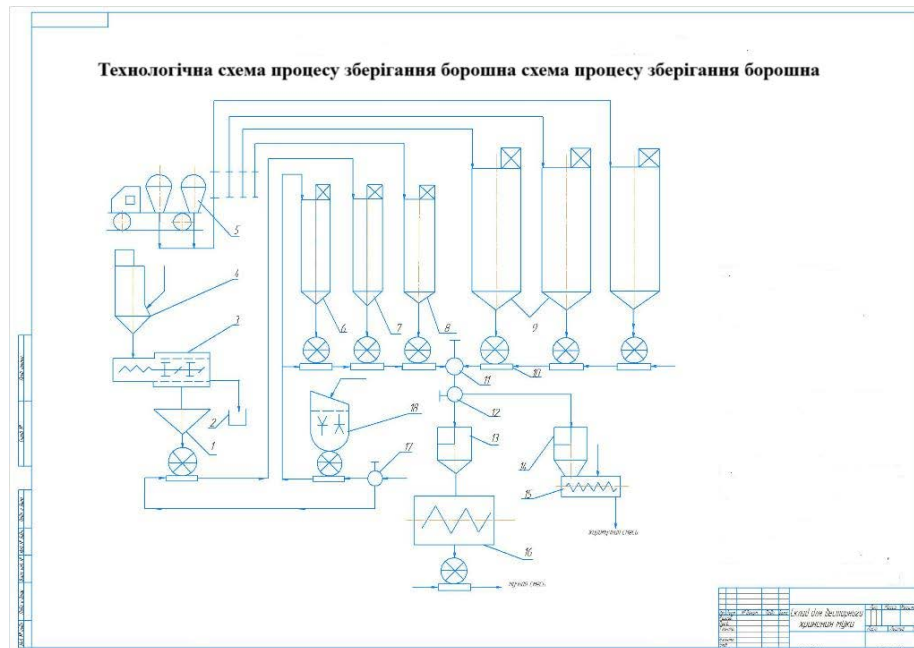
1.1 Аналіз технічної схеми зберігання борошна

Зберігання борошна є одним із найважливіших етапів у виробничому процесі хлібобулочних виробів, оскільки саме на цьому етапі зберігаються його хлібопекарські властивості. Комплексний підхід до проектування та автоматизації складів для зберігання борошна гарантує стабільну якість продукту, що є ключовим фактором для забезпечення ефективного виробництва.

Технологічний процес складу борошна включає три основні етапи: приймання борошна з млина, зберігання його в силосах та відвантаження в автотранспорт. Борошно транспортується до складу, зберігається у спеціалізованих силосах відповідно до його класу та характеристик, а потім передається для подальшого використання або транспортування до кінцевого споживача.(рис.1.1).

Безтарне зберігання борошна (БЗБ) є одним із ключових аспектів при організації та плануванні хлібопекарського чи кондитерського виробництва, а також у міні-пекарнях і цехах, що функціонують при супермаркетах та гіпермаркетах.

Впровадження сучасних систем безтарного зберігання борошна дозволяє значно підвищити ефективність виробничих процесів завдяки автоматизації, забезпечити постійний моніторинг стану продукту, а також здійснювати точний контроль обсягів сировини, що знаходиться в силосах.



1 - Проміжний бункер; 2 - Роторний живильник; 3 - Центробіжне просіювальне обладнання; 4 – Мішкозавантажувач; 5 – Автовантажувач; 6 - Силос для подрібнених відходів; 7 - Силос для висівок; 8 - Силос для борошна; 9 - Роторний живильник; 10 - Пневматичні перемикачі; 11 - Ваговий дозатор; 12 - Шнековий змішувач; 13 – Силосмішувач; 14 - Пневматичні перемикачі; 15 - Млин для подрібнення відходів

Рисунок 1.1 – Технологічна схема процесу

Система безтарного зберігання борошна зазвичай являє собою комплекс обладнання, до складу якого входять: силоси для зберігання борошна, транспортні системи для його переміщення та технологічні бункери, які забезпечують подачу продукту до виробничого обладнання.

Силоси є вертикальними спорудами, що підтримуються металевими опорами (рис.1.2). Завантаження продукту здійснюється через верхню частину, а розподіл по дну – за допомогою стисненого повітря, яке подається через систему перфорованих труб. Кожен силос обладнаний датчиками верхнього та нижнього рівнів заповнення, що дозволяє точно контролювати обсяги зберігання. Перед транспортуванням борошна через шлюзовий живильник продукт проходить через просіювальну машину, що забезпечує очищення і підготовку до подальшого використання. Силоси мають оглядові люки, систему доступу через сходи та майданчики для технічного обслуговування.



Рисунок 1.2 – Зовнішній вигляд силосів

Силоси для зберігання борошна поділяються на три основні типи залежно від матеріалу виготовлення: склопластикові, металеві (виготовлені з нержавіючої сталі) та тканинні. Кожен із цих видів має свої особливості, які визначають сферу застосування, обсяги зберігання та умови експлуатації.

Тканинні силоси найчастіше використовуються для зберігання невеликих об'ємів продукту. Вони підходять для експлуатації виключно у закритих приміщеннях, оскільки не мають достатньої стійкості до зовнішніх впливів, таких як волога або перепади температур. Основною перевагою тканинних силосів є їхня компактність, легкість встановлення та демонтажу, а також відносно низька вартість у порівнянні з іншими типами.

Металеві силоси, виготовлені з нержавіючої сталі, призначені для зберігання великих обсягів борошна. Завдяки своїй міцності та довговічності вони здатні забезпечити надійний захист сировини навіть у складних умовах експлуатації. Металеві силоси встановлюються переважно у закритих

складських приміщеннях, що дозволяє мінімізувати вплив зовнішніх факторів, таких як волога або пил. Їх можна оснастити додатковим обладнанням, зокрема системами контролю температури та вологості, що забезпечує оптимальні умови зберігання.

Склопластикові (або пластикові) силоси є найбільш універсальними з точки зору місця встановлення. Завдяки високій стійкості до кліматичних умов вони підходять як для закритих приміщень, так і для відкритих майданчиків. Склопластикові силоси характеризуються малою вагою, стійкістю до корозії та тривалим терміном експлуатації. Їх часто використовують для зберігання середніх об'ємів борошна, а також інших сипучих продуктів.

Вибір типу силосу залежить від низки факторів, таких як обсяги зберігання, умови експлуатації, бюджет підприємства та специфіка продукту. Наприклад, для зберігання борошна у великих масштабах на підприємствах із високою продуктивністю доцільніше використовувати металеві силоси із системами автоматичного клімат-контролю. Для невеликих пекарень або цехів можуть підійти тканинні або склопластикові силоси, залежно від умов зберігання та місця розташування складу.

Сучасні силоси також можна обладнати системами для моніторингу параметрів сировини, автоматизованими транспортними лініями та іншими елементами, які забезпечують високу ефективність роботи. Інтеграція таких систем у виробничі процеси дозволяє оптимізувати управління запасами, знизити витрати енергії та підвищити загальну якість кінцевого продукту.

Особливу увагу під час зберігання приділяють системам очищення повітря. Оскільки силоси є закритими спорудами, накопичення пилу та утворення вологи можуть негативно вплинути на якість борошна. Для запобігання цим процесам встановлюються промислові фільтри. Сучасні фільтри виготовляються з нержавіючої сталі, мають високу стійкість до впливу навколишнього середовища і ефективно очищають повітря навіть за умов максимальної завантаженості силосів. Вони запобігають утворенню пилу,

знижують ризик накопичення вологи і забезпечують стабільність умов зберігання.

Існує кілька варіантів схем систем безтарного зберігання борошна, які базуються на різних конструкціях силосів (бункерів) і методах транспортування сировини. Усі системи пневмотранспорту можна класифікувати на три основні типи: низького, середнього та високого тиску.

Пневмотранспорт середнього та високого тиску часто об'єднують під загальною назвою "пневмотранспорт підвищеного тиску". Такий вид транспорту також відомий як аерозольний транспорт.


Основний принцип роботи системи полягає в тому, що борошно, завантажене з автомуковоза, подається через розподільні клапани в приймальні бункери, обладнані спеціальними фільтрами для очищення повітря. Далі, завдяки використанню роторних живильників і комутаційних перемикачів, борошно транспортується до надвагового бункера, оснащеного власними фільтрами, а потім – до автоматичних вагів, підвагових бункерів і бурату. Бурат – це машина для просіювання сипучих матеріалів через сітчасте сито, закріплене на обертовому барабані різної форми (круглої, конічної, призматичної або пірамідальної).

Після цього просіяне й очищене борошно спрямовується за допомогою живильника та перемикача до виробничих силосів. Для забезпечення роботи системи використовується стислий повітряний потік, який виробляється компресорами. Повітря проходить через фільтри-глушники, після чого очищається у вологомасловідокремлювачі та фільтрах тонкого очищення й подається в ресивери. З ресиверів через повітророзподільні колектори стиснене повітря спрямовується до живильників і інших споживачів системи.

Як приклад безтарної установки зі змішаним способом транспортування борошна можна розглянути дві типові схеми:

1. У першій схемі аерозольний транспорт використовується для переміщення борошна з автомуковоза до бункера для безтарного зберігання,

після чого сировина переміщується всередині заводу за допомогою механічного транспорту (рис.1.3).



1 - живильник; 2 - бункер для зберігання борошна; 3, 10, 11 - перемикачі; 4, 5, 16 - фільтри; 6 - автоваги; 7 - підвісний бункер; 8 - бурат-просіювач; 9 - живильник; 12 - бункер виробничий; 13 - фільтр-глушник; 14 - компресор; 15 - вологомасловідокремлювач; 16 - ресивер.

Рисунок 1.3 – Схема безтарного приймання, зберігання і внутрішньозаводського аерозольного транспорту борошна

2. У другій схемі борошно транспортується аерозольним способом від автомуковоза до бункера для зберігання, далі через живильник подається в автоматичні ваги, а потім – на виробничі дільниці за допомогою механічного транспорту.

У першому випадку відсутня потреба у власній компресорній станції або повітродувках, оскільки автомуковоз уже оснащений компресорною установкою. Це суттєва перевага такої схеми.

Борошно з автомуковоза транспортується через мукопровід і перемикач до бункера безтарного зберігання. З бункера за допомогою дозатора і шнеків сировина подається до норії, потім до бурату і в автоматичний мукомір.

В інших аналогічних схемах, після проходження через бурат, борошно спрямовується до автоматичних вагів, а звідти за допомогою норій і шнеків подається до виробничих силосів.

Як приклад другої схеми безтарної установки зі змішаним способом транспортування борошна, можна розглянути діючу систему на підприємстві, яке має власну компресорну станцію. У цьому випадку борошно з автомуковоза через рукав, приймальний щиток і мукопровід потрапляє до силоса для безтарного зберігання. Зміна напрямку потоку борошна в силосі здійснюється за допомогою двопозиційних перемикачів, а повітря, що транспортує борошно, видаляється через фільтр.

З силоса борошно транспортується живильником і через двоходовий перемикач подається до фільтра-розвантажувача і автоматичних вагів. Далі воно потрапляє до підвагового бункера, норії, бурату і за допомогою шнеків спрямовується до виробничих силосів, дріжджових або опарних відділень. Для аерації силосів безтарного зберігання додатково встановлено вентилятор.

Щодо регулювання подачі борошна, у першій схемі це здійснюється шляхом зміни частоти обертання ротора в дозаторах. У другій схемі регулювання виконується за допомогою роторних живильників, оснащених варіаторами швидкостей.

Обидві схеми мають свої переваги залежно від потреб підприємства. Використання аерозольного транспорту дозволяє швидко й ефективно переміщувати борошно на великі відстані, уникаючи втрат та забруднення. Змішаний підхід, який включає і пневматичний, і механічний транспорт, забезпечує гнучкість і адаптацію системи до особливостей виробничого процесу.

Сучасні безтарні установки можуть також бути оснащені автоматизованими системами моніторингу стану сировини, що дозволяє відстежувати параметри вологості, температури та рівня завантаження силосів у реальному часі. Такий підхід сприяє зниженню втрат продукції, оптимізації логістики та зменшенню експлуатаційних витрат на підприємстві.

Проектування складів для зберігання борошна вимагає врахування фізико-механічних і біохімічних властивостей продукту. До найважливіших фізичних характеристик належать вологість, насипна густина, гранулометричний склад, фрикційні властивості та здатність до плинності. Вміст води, наприклад, може коливатися в межах 12,5–15%, і цей показник слід стабілізувати для запобігання псуванню. Густина та гранулометричний склад впливають на проектування конструкції силосів і систем транспортування. До біохімічних властивостей, які також мають значення, відносяться вміст білків, жирів, золи, кислотність, а також структура крохмалю, яка визначає подальше використання борошна у виробництві.

1.2 Взаємозв'язок параметрів керування мікрокліматом силоса для безтарного зберігання борошна

Зберігання борошна на складах безтарного зберігання є складним технологічним процесом, який значною мірою залежить від впливу навколишнього середовища, зокрема таких факторів, як температура, тиск, вологість тощо. Якщо не впроваджувати відповідних заходів контролю, під впливом зазначених факторів хлібопекарські властивості борошна можуть


змінюватися, що призведе до виходу його параметрів за межі допустимих значень, унеможливлуючи використання продукту у виробничих процесах.

Припустимо, що склад безтарного зберігання борошна знаходиться в експлуатації. Під впливом зовнішніх умов стан борошна може змінюватися, спочатку переходячи в проміжний стан, а потім — у кінцевий. Наприклад, підвищена вологість повітря може спричинити злежування продукту, що ускладнює його транспортування й подачу до виробничих ліній. Крім того, зміна температурного режиму може призводити до підвищення активності мікроорганізмів, що впливає на якість і безпечність продукту.

Для запобігання цим негативним змінам необхідно ретельно організувати умови зберігання. Це включає контроль температурного режиму за допомогою автоматичних систем моніторингу, підтримання стабільного рівня вологості повітря за допомогою осушувачів та систем вентиляції, а також регулярне очищення й аерацію силосів для запобігання утворенню конденсату і накопичення пилу.

Необхідно розробити математичну модель, яка описує процес зберігання борошна на складі. Базова математична модель цього процесу може бути представлена у вигляді спрямованого динамічного графа (рис. 1.4.). Такий підхід дозволяє враховувати різноманітні фактори, що впливають на стан борошна під час зберігання, та відображає динаміку його переходів між різними станами.

Спрямований динамічний граф моделює систему як сукупність вузлів (станів) і зв'язків між ними, що описують можливі переходи борошна з одного стану в інший під впливом зовнішніх факторів, таких як температура, вологість повітря, вентиляція та інші параметри. Наприклад, початковий стан борошна при завантаженні на склад може змінюватися залежно від умов зберігання, переходячи в проміжні або кінцеві стани.

Рисунок 1.4 – Спрямований динамічний граф $G(t)$

Для побудови такої моделі важливо враховувати фізико-хімічні властивості борошна, які впливають на його поведінку в умовах складу: насипну густину, вологість, гранулометричний склад, теплопровідність та інші характеристики. Крім того, необхідно моделювати процеси, пов'язані з термодинамікою, такими як теплопередача між середовищем і продуктом, а також взаємодію з повітряним потоком у системі вентиляції.

Розширена математична модель повинна включати залежності між зовнішніми умовами та ключовими параметрами борошна, такими як рівноважна вологість, швидкість поглинання або віддачі вологи, а також вплив температурних коливань. Вона може бути описана системою диференціальних рівнянь або матричних рівнянь, що враховують вплив кожного фактора.

Така модель є основою для прогнозування стану борошна протягом періоду зберігання та визначення оптимальних параметрів мікроклімату на складі. Її можна також використовувати для розробки автоматизованих систем управління, які підтримують стабільні умови зберігання та забезпечують високу якість продукту.

$$G(t)\{V(t), Y(t), X(t), A(t), B(t), \int L_{ij}\} \quad (1.1)$$

з відображеннями:

$$\begin{aligned} \alpha_{bij}\{V(t)\} &\Rightarrow \{Y(t)\}; \\ \alpha_j \{Y(t)\} &\Rightarrow \{X(t)\}, \alpha_j \{X\} \Rightarrow \{X\}; \\ \alpha_{a_{ij}}\{X(t)\} &\Rightarrow \{Y(t)\}. \end{aligned} \quad (1.2)$$

Коефіцієнти та лінійні оператори у цій моделі є функціями часу. Індекс **i** позначає вихідний адрес відображення, тоді як індекс **j** вказує на адресу, куди спрямовується відображення вершини графа.

Рівняння (1.1) та (1.2) описують базову математичну модель процесу зберігання у множинній формі. Для її побудови початковий стан системи моделюється за допомогою суматорів, інтегральне відображення графа — за допомогою інтеграторів, а дуги, що характеризують пропорційне відображення, задаються відповідними коефіцієнтами [2].

Минаючи проміжні етапи обчислень, у середовищі Matlab можна побудувати модель процесу зберігання у вигляді схеми змінних стану. З отриманої схеми витікає, що кожен етап процесу зберігання пов'язаний з іншим через систему рівнянь, яка враховує як динамічні, так і статичні параметри.

Модель змінних станів дає можливість описати весь процес зберігання у вигляді сукупності інтегрально-диференціальних рівнянь. У цих рівняннях відображається вплив зовнішніх умов (температури, вологості, тиску) на основні параметри борошна, такі як його вологість, щільність, сипучість та інші фізико-хімічні характеристики.

Окрім побудови математичної моделі, така схема дозволяє аналізувати і оптимізувати управління процесом зберігання. Наприклад, можна оцінити, як зміни в параметрах навколишнього середовища або у системі вентиляції впливають на якість борошна. Додатково модель можна використовувати для розробки рекомендацій щодо вибору оптимальних режимів зберігання або впровадження автоматизованих систем контролю кліматичних умов.

Впровадження таких моделей у програмні комплекси на зразок Matlab забезпечує не лише наукову основу для подальшого дослідження, але й практичний інструмент для управління процесом зберігання у реальному виробництві.

$$\begin{aligned} Z_1''(t) + a_{21}(t)Z_1'(t) + a_{11}(t)Z_1(t) &= b_{11}(t)v_1(t) + b_{21}(t)v_2(t); \\ Z_2''(t) + a_{42}(t)Z_2'(t) + a_{32}(t)Z_2(t) &= b_{12}(t)v_1(t) + b_{22}(t)v_2(t); \\ Z_3''(t) + a_{63}(t)Z_3'(t) + a_{53}(t)Z_3(t) &= b_{13}(t)v_1(t) + b_{23}(t)v_2(t); \end{aligned} \quad (1.3)$$

Відповідно до вищезазначеного, можна виділити три ключові параметри мікроклімату, які найбільше впливають на якісні показники борошна під час його зберігання в силосах:

1. *Температура повітря.*
2. *Вологість повітря.*
3. *Вентиляція.*

Для аналізу впливу цих факторів необхідно визначити динамічні залежності між параметрами мікроклімату, керуючими діями та основними збурюючими впливами.

Мікроклімат у технологічному приміщенні підтримується шляхом регулювання інтенсивності вентиляції та підготовки повітря, яке подається. Для цього використовується пряма система повітряного обігріву, що є однією з найпоширеніших. Особливістю цієї системи є висока кратність повітрообміну, яка необхідна для забезпечення заданого хімічного складу повітря, а також відносно низькі постійні часу у каналах управління.

Процес досягнення необхідної температури у приміщенні відбувається шляхом подачі повітря, яке було попередньо підігріте до розрахункових параметрів за допомогою промислового кондиціонера. Кондиціонер підключений до системи гарячого водопостачання, що дозволяє гнучко регулювати температуру.

Регулювання вологості здійснюється шляхом дозованої подачі пари в систему зволоження, яка інтегрована з каналами кондиціонера. Парогенератор

виробляє пару, кількість якої регулюється клапанами залежно від рівня оновлення повітря у приміщенні через систему вентиляції.

Керування вентиляцією реалізується шляхом змішування свіжого повітря із повітрям, яке вже циркулює у приміщенні. Цей процес забезпечується зміною продуктивності системи вентиляції.

Для побудови узагальненої структури взаємозв'язку вхідних, вихідних і збурюючих параметрів (рис. 1.5) приймемо такі припущення:

- Вплив теплового випромінювання сонячного світла на тепловий баланс приміщення не враховується.
- Теплова інерція стін приміщення не береться до уваги.
- Тепловиділення від внутрішнього технологічного обладнання (наприклад, електромережі, освітлення тощо) ігнорується.
- Процеси радіаційного теплообміну між внутрішніми поверхнями приміщення не враховуються.
- Об'єм повітря обмежений внутрішнім простором приміщення. При цьому повітря вважається нестисливим із постійною масою.
- Просторовий розподіл змінних, які описують мікроклімат, не враховується.
- Зміна біомаси продукції у процесі технологічного циклу ігнорується.
- Об'єкт управління розглядається як квазістаціонарний.

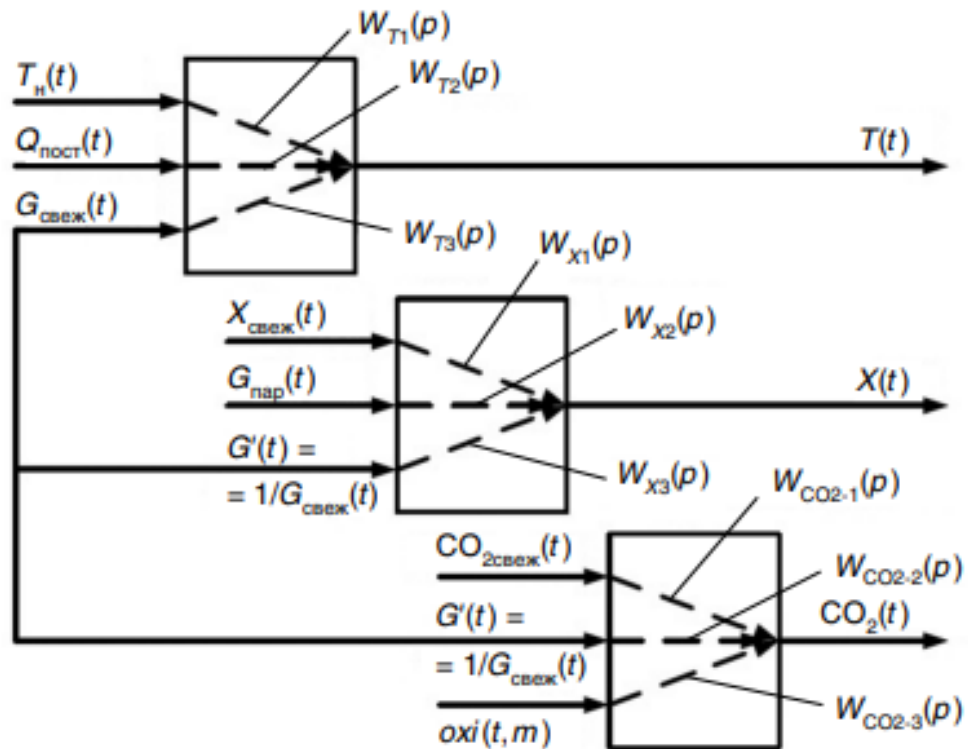


Рисунок 1.5 – Узагальнена структура взаємозв'язку вхідних, вихідних і збурюючих параметрів

У структурній моделі використовуються такі позначення:

$T_n(t)$ — зовнішня температура повітря, °С;

$Q_{\text{пост}}(t)$ — теплові надходження від системи обігріву, Вт;

$G_{\text{свеж}}(t)$ — витрата свіжого повітря для вентиляції приміщення, кг/с;

$W_{T1}(p)$ — передавальна функція для зміни внутрішньої температури залежно від зовнішньої;

$W_{T2}(p)$ — передавальна функція для впливу теплових надходжень на температуру повітря;

$W_{T3}(p)$ — взаємозв'язок між зміною температури повітря $T(p)$ та витратою свіжого повітря $G_{\text{свеж}}$;

$T(t)$ — температура внутрішнього повітря в силосі;

$X_{\text{свеж}}(t)$ — абсолютна вологість свіжого повітря;

$G_{\text{пар}}(t)$ — витрата пари;

$G'(t)$ — взаємозв'язок між вологістю повітря та витратою повітря;

$WX1(p)$ — передавальна функція залежності між внутрішньою та зовнішньою вологістю;

$WX2(p)$ — передавальна функція, що пов'язує вологість повітря з впливом від витрати пари $G_{пар}$;

$WX3(p)$ — передавальна функція, що показує залежність вологості повітря від витрати свіжого повітря $G'(t)$;

$X(t)$ — вологість внутрішнього повітря;

$CO2_{свеж}(t)$ — абсолютний вміст CO_2 у зовнішньому повітрі;

$oxi(t, m)$ — збурюючі впливи;

$WCO2-1(p)$ — передавальна функція впливу концентрації CO_2 у приточному повітрі;

$WCO2-2(p)$ — передавальна функція для витрати повітря;

$WCO2-3(p)$ — передавальна функція для зміни концентрації CO_2 у повітрі технологічного приміщення під впливом збурень $oxi(t, m)$;

$CO2(t)$ — концентрація CO_2 у внутрішньому повітрі.

Аналізуючи структурну схему, можна дійти висновку, що процес стабілізації мікроклімату складу БХМ характеризується множинними зв'язками між вихідними параметрами та зовнішніми факторами. Для врахування цих зв'язків необхідно застосовувати багатозв'язну систему автоматичного регулювання. З точки зору автоматизованого управління склад БХМ є складним багатозв'язним об'єктом, де зв'язки мають нелінійний характер і вимагають автономного управління для кожного вихідного параметра.

Такий підхід дозволяє забезпечити точність регулювання мікроклімату та створити умови, що мінімізують вплив зовнішніх факторів на якість зберігання борошна, а також дозволяє спростити модель, зробивши її більш зручною для аналізу і впровадження в автоматизовані системи управління мікрокліматом. Крім того, така структура сприяє точнішому контролю за

якістю зберігання борошна, зводячи до мінімуму вплив несприятливих зовнішніх факторів.

Висновки до розділу

У цьому розділі було розглянуто аспекти організації процесу зберігання борошна в системах бестарного зберігання з урахуванням основних факторів, що впливають на якість продукту. Досягнення стабільності мікроклімату у складах бестарного зберігання є ключовим завданням, оскільки від температури, вологості та хімічного складу повітря залежить збереження фізико-хімічних властивостей борошна.

Було визначено, що ефективність підтримання мікроклімату залежить від організації вентиляції, системи підготовки повітря, контролю температури та вологості. Впровадження промислових кондиціонерів, систем подачі пари та регулювання складу повітря забезпечує підтримання оптимальних умов зберігання.

Аналіз структурної схеми управління мікрокліматом складу показав, що система автоматичного регулювання для таких об'єктів є багатозв'язною, що вимагає врахування нелінійних залежностей між зовнішніми та внутрішніми параметрами. Автономне управління кожним параметром дозволяє забезпечити стабільність та мінімізувати вплив зовнішніх збурень.

Таким чином, у результаті дослідження сформовано основні підходи до моделювання та автоматизації управління процесом зберігання борошна. Отримані результати можуть слугувати основою для розробки ефективних технічних рішень та вдосконалення існуючих систем зберігання.

РОЗДІЛ 2

ВИКОРИСТАННЯ НЕЙРОННИХ МЕРЕЖ У ПРОЦЕСІ ЗБЕРІГАННЯ БОРОШНА І ВИМОГИ ДО РОЗРОБЛЮВАНОЇ СИСТЕМИ

Технологічні процеси у харчовій промисловості характеризуються високою складністю, багатопараметричністю та часто включають нелінійні взаємозв'язки між ключовими змінними. Традиційні засоби автоматизації, хоча і залишаються основою для управління процесами, поступово втрачають здатність забезпечувати необхідний рівень продуктивності, гнучкості та надійності. Стрімке зростання конкуренції на ринку ставить перед підприємствами завдання впровадження сучасних інноваційних методів контролю та управління якістю готової продукції.

Серед найбільш перспективних підходів виділяється використання штучних нейронних мереж (ШНМ). Ці технології пропонують адаптивні рішення для аналізу великих масивів даних, моделювання складних процесів та прийняття рішень у реальному часі. Особливо актуальним це стає у харчовій промисловості, де існує потреба у точному прогнозуванні показників якості продукції, оптимізації технологічних процесів та зменшенні витрат ресурсів.

Протягом останніх десятиліть спостерігається зростання кількості досліджень, присвячених успішному впровадженню нейромережевих алгоритмів у виробничі процеси. Зокрема, ШНМ використовуються для контролю за мікрокліматом у складах, управління процесами ферментації, оптимізації технологій обробки сировини та прогнозування термінів зберігання продуктів.

Крім того, нейромережеві моделі можуть інтегруватися в системи автоматичного управління, де вони здатні враховувати нелінійності та динамічні зміни технологічного середовища. Їх гнучкість дозволяє адаптуватися до нових умов виробництва та забезпечувати стабільність процесів навіть при виникненні непередбачуваних ситуацій.

Таким чином, використання штучних нейронних мереж у харчовій промисловості відкриває нові можливості для підвищення ефективності виробництва, зниження собівартості продукції та забезпечення її високої якості, що стає критично важливим у сучасних умовах глобальної конкуренції.

2.1. Архітектури та типи нейронних мереж

Такі науковці, як Кохонен, Хопфідл, Румельхарт, Хінтон і Вільямс, стали першими у застосуванні штучних нейронних мереж для вирішення практичних завдань у різних галузях. Саме вони заклали теоретичну основу для навчання багат шарових персептронів, запропонувавши алгоритми, що забезпечують ефективне налаштування вагових коефіцієнтів. Їх дослідження відкрили шлях до використання нейромереж у завданнях класифікації, прогнозування, оптимізації та розпізнавання образів .

Нейронні мережі базуються на структурі, основною одиницею якої є штучний нейрон. Нейрон являє собою обчислювальний елемент, який має кілька входів, вихід і нелінійну активаційну функцію. Ця структура дозволяє нейрону обробляти інформацію та генерувати вихідний сигнал залежно від вхідних даних. Завдяки своїм властивостям нейрони здатні моделювати складні функціональні залежності, що виникають у реальних процесах.

У науковій літературі виділяють кілька типів нейронів, залежно від типу їх активаційної функції. Серед найпоширеніших типів:

- Нейрони із сигмоїдною функцією активації, які широко застосовуються у багат шарових персептронах завдяки їхній здатності обмежувати вихідний сигнал у межах від 0 до 1.

- Нейрони з радіальною базисною функцією (RBF), які використовуються у мережах, орієнтованих на апроксимацію функцій і кластеризацію.

Сигмоїдні нейрони мають активаційну функцію, яка згладжено передає вхідні сигнали у вихідний діапазон, що дозволяє уникнути різких стрибків. Вихідний сигнал такого нейрона, y , обчислюється за формулою:

$$y = \phi(\sum_{j=1}^n w_j X_j + w_0) \quad (1.4)$$

Активаційна функція f у нейронних мережах зазвичай є сигмоїдальною (рис. 2.1а), що забезпечує плавний перехід від одного стану до іншого. Такі функції широко використовуються у нейронах, оскільки вони дозволяють моделювати нелінійні залежності та обмежувати вихідний сигнал у заданих межах, наприклад, від 0 до 1 або від -1 до 1. Нейронні сенсори — це спеціалізовані мережі, побудовані з використанням сигмоїдальних нейронів, що надає їм високу точність і здатність адаптуватися до змін параметрів середовища.

Для вирішення складних обчислювальних задач необхідно використовувати нейронні мережі, які мають не менше двох шарів. Такі мережі називаються багат шаровими і відзначаються своєю здатністю обробляти складні багатовимірні залежності. У багат шарових мережах перший шар (вхідний) відповідає за початкову обробку даних, тоді як приховані шари виконують функції узагальнення і нелінійного перетворення, а вихідний шар формує результати.

На відміну від цього, радіально-базисні нейронні мережі складаються лише з одного шару, де кожен нейрон має радіально-базисну функцію активації. (рис. 2.2б). Такі мережі добре підходять для завдань класифікації, апроксимації та кластеризації даних. Радіально-базисні нейрони є простими за структурою, але ефективними в задачах, де важлива обробка локальної інформації.

$$y = \sum_{j=1}^n w_j R_j(X) + w_0 \quad (1.5)$$

$$R_j(X) = \phi(X, C_j) \quad (1.6)$$

Тут C_j - це координати попередньо вибраного центру, що відповідає нульовому входу нейрона. Функція f може бути реалізована різними способами, як і в сигмоїдних нейронах, але має характерну форму, як показано на рисунку.




Рисунок 2.2 - Функція f сигмоїдального (а) та радіально-базисного (б) типів

Таким чином, сигмоїдальні та радіально-базисні нейрони мають свої унікальні особливості та застосування. Сигмоїдальні нейрони найкраще підходять для задач, де важливі глобальні залежності, тоді як радіально-базисні нейрони ефективніші у локальних обчисленнях. Поєднання цих підходів дозволяє створювати нейронні мережі, здатні вирішувати широкий спектр завдань, включаючи прогнозування, розпізнавання образів та аналіз даних.

В архітектурі багат шарового перцептрона нейрони організовані пошарово, де кожен нейрон i -го шару з'єднаний з усіма нейронами наступного шару ($i+1$). Вихідний сигнал кожного нейрона попереднього шару служить вхідним сигналом для всіх нейронів наступного шару. Цей підхід забезпечує здатність мережі до ефективного обробки даних завдяки взаємодії між різними

рівнями абстракції. Багатошарова нейронна мережа зі зворотним зв'язком, яка ілюструє цю структуру, зображена на рисунку 2.3.

Архітектура багатошарової нейронної мережі зазвичай описується у вигляді $N_{n_0, n_1, \dots, n_{m-1}, n_m}$ де:

- n_0 — кількість входів у першому (вхідному) шарі мережі;
- $n_1, \dots, n_{m-1}, \dots, n_{m-1}$ — кількість нейронів у прихованих шарах;
- n_m — кількість нейронів (та виходів) у вихідному шарі.

Кожен шар виконує окремий етап обробки даних. Вхідний шар приймає вихідні дані, приховані шари обробляють інформацію за допомогою нелінійних функцій активації, а вихідний шар генерує результати у вигляді прогнозів або класифікацій.

Багатошарова структура дає змогу вирішувати широкий спектр складних задач, включаючи розпізнавання образів, класифікацію даних, апроксимацію функцій і прогнозування. При цьому кількість нейронів у кожному шарі та кількість шарів визначаються залежно від складності задачі й особливостей вхідних даних.

Особливо важливою особливістю є можливість зворотного зв'язку. Завдяки алгоритму зворотного поширення помилки (backpropagation) мережа може навчатися шляхом оновлення вагових коефіцієнтів на основі похибки між фактичним і цільовим виходом. Це забезпечує адаптивність системи та її здатність до самовдосконалення.

Така архітектура ефективно використовується в різноманітних галузях, зокрема в розпізнаванні мови, аналізі зображень, автоматизації технологічних процесів і розробці систем штучного інтелекту.




Рисунок 2.3 - Багатошарова нейронна мережа прямого розподілу

Одним із ключових викликів у проектуванні нейронних мереж є вибір оптимальної кількості нейронів і шарів. Це завдання фактично зводиться до визначення необхідної кількості вагових коефіцієнтів, які впливають на здатність мережі навчатися та узагальнювати дані. Згідно з численними дослідженнями, кількість нейронів у прихованих шарах часто пов'язують із кількістю можливих класів або образів, які мережа повинна розпізнавати.

Однак у багатьох випадках точне визначення кількості нейронів є складним завданням, тому використовують емпіричні методи або приблизні оцінки. Наприклад, багато наукових джерел [7], [8] свідчать, що три- або чотиришарові мережі є оптимальними для вирішення більшості практичних задач, оскільки вони забезпечують високу швидкість збіжності алгоритму навчання.

Крім того, кількість нейронів у шарах можна коригувати в процесі роботи. Це дозволяє адаптувати архітектуру мережі до конкретних завдань, особливо коли проблема має високий ступінь невизначеності. Наприклад, додавання нейронів може підвищити здатність мережі до моделювання складних залежностей, тоді як їх видалення допомагає зменшити ймовірність перенавчання.

Важливо зазначити, що вихід нейронної мережі прямого поширення однозначно залежить від її входів. Відсутність циклічних зв'язків у таких мережах спрощує їхню математичну модель і навчання. Для забезпечення динамічності нейронних мереж існують кілька підходів:

Розширення архітектури зворотного зв'язку. У нейронні мережі додаються рекурентні з'єднання, які забезпечують облік попередніх станів мережі. Це дозволяє обробляти часові ряди або послідовності даних.

Динамічна зміна вагових коефіцієнтів. Використовуються алгоритми адаптивного навчання, які модифікують ваги мережі в процесі її функціонування залежно від вхідних даних і їхніх особливостей.

Використання рекурентних нейронних мереж (RNN). Такі мережі дозволяють враховувати контекст у задачах з часовою залежністю (наприклад, розпізнавання мови або аналіз сигналів).

Інтеграція стохастичних елементів. Деякі мережі включають елементи випадковості в процес обробки даних, що може підвищити їхню стійкість до шуму.

Загалом, вибір архітектури нейронної мережі має враховувати специфіку задачі, доступний обсяг даних і обчислювальні ресурси. Використання адаптивних підходів до побудови мережі дозволяє підвищити її ефективність і універсальність у різних умовах.

Для ефективної роботи системи управління (СУ) на основі нейронних мереж можуть застосовуватися кілька підходів до подачі даних і організації зв'язків між нейронами:

– Паралельна подача даних у послідовні моменти часу. Це означає, що значення, які обробляються системою управління, подаються на входи нейронної мережі одночасно, але з різними часовими відмітками (рис. 2.4а). Такий підхід дозволяє забезпечити часовий контекст, необхідний для аналізу динамічних процесів.

– Створення локального зворотного зв'язку. У цьому випадку нейронна мережа використовує внутрішні петлі між своїми вузлами, що

дозволяє їй враховувати попередні стани. Це важливо для вирішення задач із часовою залежністю, наприклад, прогнозування або аналізу послідовностей даних .

– Використання глобального зворотного зв'язку. Такий підхід передбачає зв'язок виходів нейронної мережі із входами через зовнішнє середовище або спеціальні алгоритми. Прикладами можуть бути мережі Хопфілда, які використовуються для задач оптимізації, або метод інверсного часового розподілу помилок, що застосовується для навчання рекурентних мереж (рис. 2.4б). Глобальний зворотний зв'язок додає мережі можливість враховувати результати своєї роботи для подальшого коригування.

Налаштування нейронної мережі здійснюється шляхом поступової ітераційної зміни вагових коефіцієнтів w_j . У процесі навчання ваги оновлюються таким чином, щоб звести до мінімуму різницю між фактичним виходом мережі та цільовим значенням. Для цього можуть використовуватися різноманітні алгоритми, зокрема:

- Метод градієнтного спуску, що змінює ваги пропорційно до градієнта функції помилки;
- Алгоритми адаптивного навчання, такі як Adam або RMSProp, які автоматично налаштовують швидкість навчання;
- Глобальні методи оптимізації, наприклад, еволюційні алгоритми або пошук на основі рою частинок, що забезпечують ширший пошук у просторі ваг.

Додатково, вибір ітераційного підходу залежить від задачі, яка вирішується, та обсягу доступних обчислювальних ресурсів. Ретельне налаштування ваг дозволяє значно підвищити ефективність роботи нейронної мережі, забезпечуючи її здатність до узагальнення та адаптації до нових даних.




Рисунок 2.4 - Два основні підходи для надання нейронній мережі динамічних властивостей: за допомогою декомпозиції часових рядів (а) та глобального зворотного зв'язку (б).

– Декомпозиція часових рядів (позначена як а). Цей підхід передбачає подачу на входи нейронної мережі значень змінної в послідовні моменти часу. Це забезпечує аналіз змін у даних у часовому контексті. Наприклад, для прогнозування значення на наступний момент часу використовуються попередні значення ряду. Такий метод корисний для вирішення задач, де необхідно враховувати динаміку системи, як-от аналіз трендів або виявлення аномалій.

– Глобальний зворотний зв'язок (позначений як б). Цей метод створює зовнішній зворотний зв'язок між виходами і входами мережі через зовнішнє середовище або внутрішні алгоритми. Глобальний зворотний зв'язок дозволяє мережі реагувати на власні результати, що важливо для стабільного управління складними нелінійними системами. Наприклад, в мережі Хопфілда або в алгоритмах рекурентних нейронних мереж, таких як LSTM, така структура допомагає враховувати довготривалі залежності.

Ці два підходи ілюструють, як нейронні мережі можуть бути адаптовані для роботи з часозалежними даними, підвищуючи їхню функціональність у задачах моделювання, прогнозування та автоматичного управління.

Підсумовуючи, можна зазначити, що застосування нейронних мереж у технологічних процесах охоплює низку ключових компонентів, які забезпечують ефективне управління, оптимізацію і прогнозування. Основні елементи систем, що використовують нейромереві технології, включають:

- Контролер. Це центральна ланка системи, що забезпечує автоматизацію процесів на основі заданих параметрів і результатів обробки нейронної мережі.

- Метод управління об'єктом. Визначає спосіб взаємодії нейронної мережі з процесом, зокрема, як моделюються та оптимізуються параметри технологічного об'єкта .

- Оптимальний фільтр об'єкта керування. Використовується для виділення корисного сигналу серед шуму, що є важливим для коректного навчання та управління нейронною мережею .

- Комбіновані контролери. Це контролери, що об'єднують нейронні мережі з іншими підходами, такими як лінійні моделі або контролери на основі нечіткої логіки, для підвищення точності та адаптивності системи.

- Інші типи конфігурацій контролерів. Включають гібридні моделі, що розробляються для специфічних задач і можуть бути налаштовані залежно від вимог технологічного процесу .

- Класифікатори та розпізнавачі образів. Використовуються для аналізу вхідних даних, виявлення закономірностей і прийняття рішень на основі результатів розпізнавання .

Сучасні нейромереві системи демонструють значний потенціал для адаптивного управління навіть у складних, нелінійних середовищах. Їхнє широке впровадження сприяє оптимізації технологічних процесів, зниженню витрат і підвищенню якості продукції. Розвиток цих систем дозволяє інтегрувати їх у різноманітні галузі, забезпечуючи прогрес у сферах автоматизації та аналітики.

2.2 Вимоги до реалізації системи на базі нейронних мереж

Реалізація нейронної системи регулювання (НС-Р) включає низку етапів, які охоплюють аналіз технологічного процесу як об'єкта автоматизації та впровадження інтелектуальних технологій у виробництво (рис. 2.5).

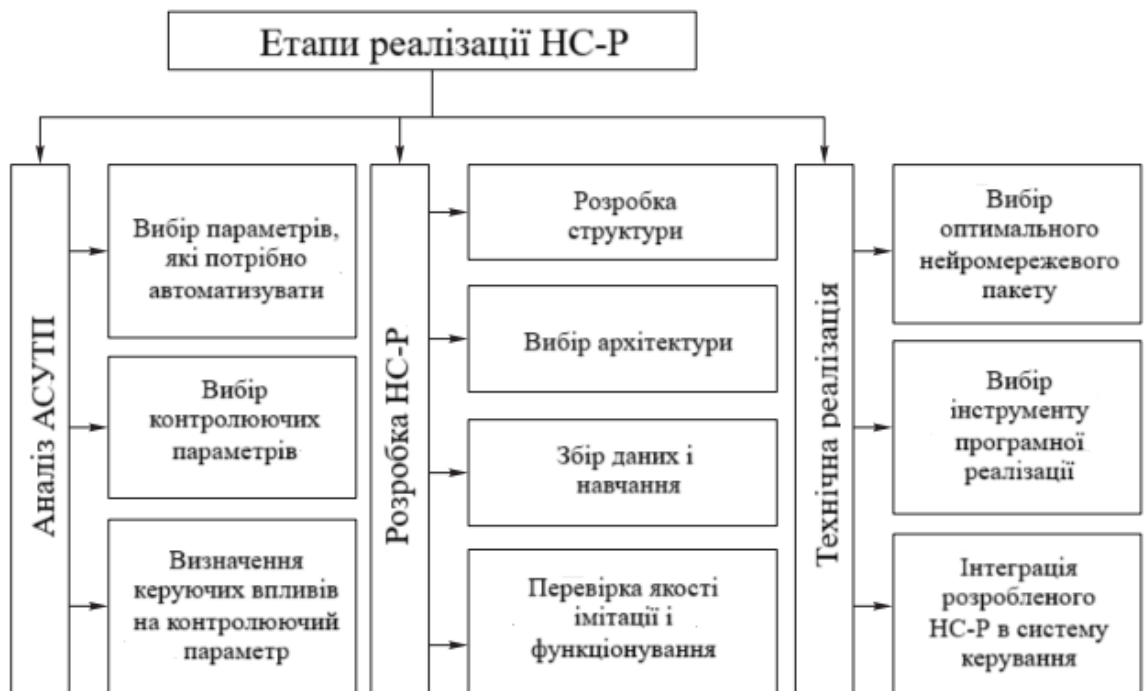


Рисунок 2.5 – Етапи реалізації НС-Р

На кожному етапі розробки НС-Р необхідно створювати та використовувати бази даних, які містять автоматично вимірювані, контрольовані та керовані параметри. Крім того, важливо чітко сформулювати правила ведення технологічного процесу бестарного зберігання борошна в силосах для подальшого формування керуючих впливів, які реалізовуватимуться системою.

Розроблена НС-Р представлена у вигляді інформаційно-обчислювального комплексу (рис. 2.6). Основними складовими цього комплексу є:

- База даних, яка акумулює, структурує та зберігає інформацію про вимірювані параметри процесу.
- Нейронна мережа, що виконує основну роль у прогнозуванні, оптимізації та управлінні.
- Модуль навчання, який забезпечує адаптацію нейронної мережі до нових умов шляхом алгоритмічного навчання.
- Модуль формування рішень, що відповідає за генерацію керуючих впливів на основі аналізу даних.

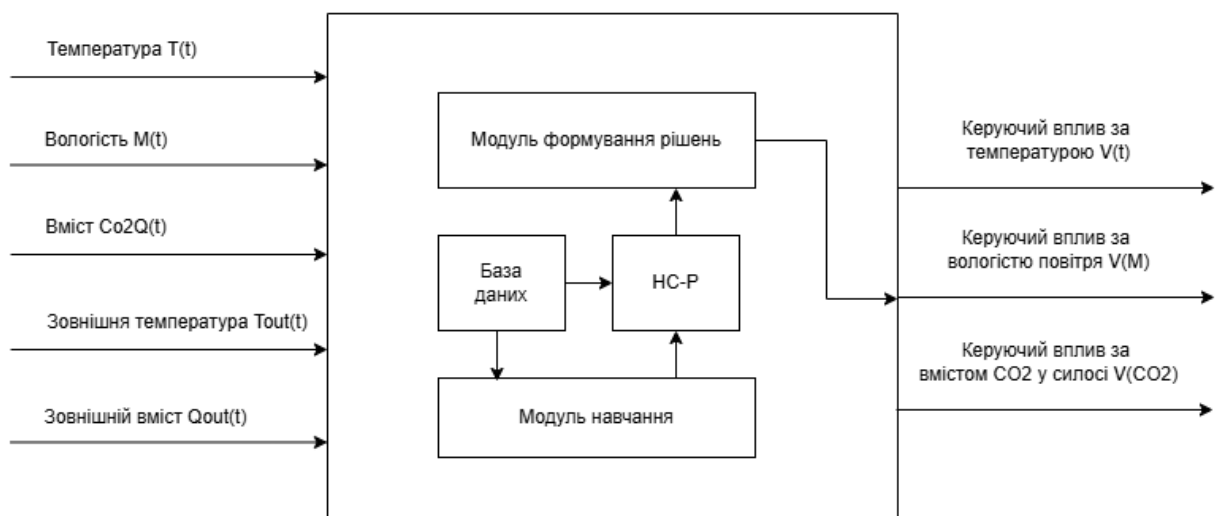


Рисунок 2.6 - Структура НС-Р

Використання SCADA-системи забезпечує передачу інформації про автоматично вимірювані параметри (контрольовані, керуючі та збурюючі впливи) на вхід НС-Р. Ці дані спершу надходять у базу даних, де структуровано зберігаються для подальшого аналізу.

Після цього дані передаються на модуль навчання, де нейронна мережа проходить навчання відповідно до заданого алгоритму. Разом із поточними параметрами в базу даних записуються й передаються на нейронну мережу попередні значення мікрокліматичних параметрів, інформація про керуючі впливи та початкові характеристики сировини. Такий підхід дозволяє надати

нейронній мережі динамічних властивостей, що є важливим для адаптивного управління в реальному часі.

Таким чином, майбутня інтеграція НС-Р забезпечувати ефективне управління технологічними процесами, мінімізуючи вплив зовнішніх збурюючих факторів і підвищуючи якість готової продукції. Система не лише оптимізує параметри процесу, але й адаптується до змін умов, що особливо важливо для складних виробничих процесів, таких як зберігання борошна.

Після завершення навчання нейронна мережа через модуль формування рішень видає рекомендації щодо управління технологічним процесом оператору-технологу. У разі повної автоматизації система може напряду надсилати керуючі впливи на виконавчі механізми. На виході нейронної системи регулювання (НС-Р) отримуються фізичні параметри керуючих впливів:

- Температура $VT(t)$;
- Вологість $VM(t)$;
- Контроль концентрації CO_2 $V_{CO_2}(t)$, що виключає його накопичення у силосах.

Основою НС-Р є нейронна мережа прямого розповсюдження типу "багатошаровий персептрон" з одним прихованим шаром і трьома вихідними параметрами. У цій архітектурі кожен нейрон попереднього шару має зв'язок з усіма нейронами наступного шару, що забезпечує високу інтеграцію в обробці даних (рис. 2.7).

На вхідний шар нейронної мережі подається вектор вхідних параметрів X_n (див. таблицю), який включає інформацію про стан мікроклімату в силосі, технологічні показники та збурюючі впливи. Прихований шар складається з 11 нейронів, кожен з яких генерує сигнали, що через ваги синаптичних зв'язків передаються на вихідний шар. Ваги синаптичних зв'язків між h -м нейроном прихованого шару та m -м нейроном вихідного шару позначаються як w_{hm} .

Коригування вагових коефіцієнтів здійснюється за допомогою градієнтного методу зворотного поширення помилки. Навчання нейронної

мережі проводилося з учителем, що забезпечило точність і адаптивність системи до специфічних умов зберігання борошна

0

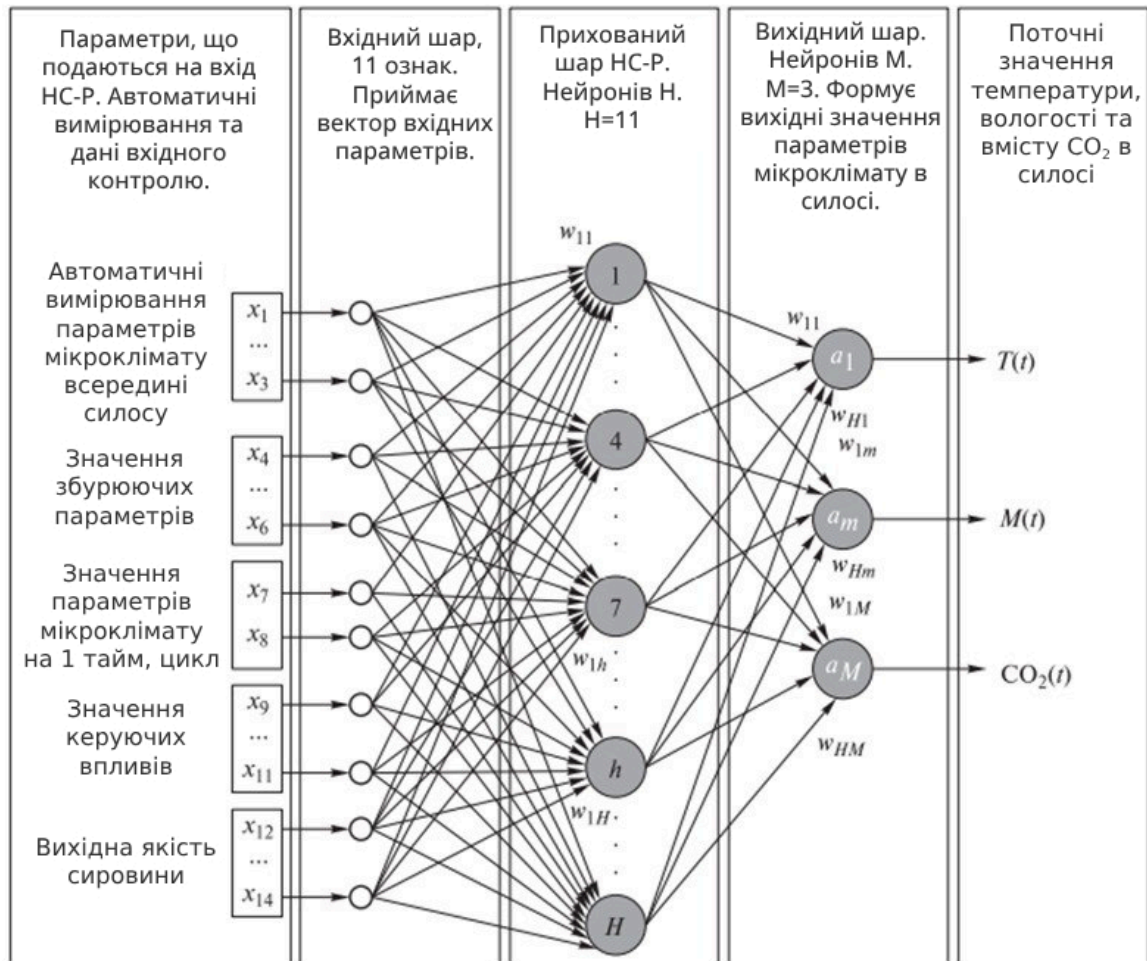


Рисунок 2.7 – Структура нейронної мережі

Інтерактивність штучної нейронної мережі зі зворотним поширенням помилки дозволяє ефективно вирішувати задачі, пов'язані з недостатньою визначеністю параметрів ПІД-регулювання. Це пояснюється здатністю нейромережі апроксимувати будь-яку нелінійну функцію, її простою структурою та особливостями алгоритму навчання.


Додаткові переваги системи:

– Гнучкість та універсальність: здатність адаптуватися до змінних умов експлуатації.

- Мінімізація помилок: забезпечується за рахунок навчання та оптимізації вагових коефіцієнтів.
- Підвищення ефективності: інтеграція НС-Р дозволяє автоматизувати складні процеси, скорочуючи людський фактор і знижуючи ймовірність помилок у регулюванні.

Таким чином, розробка та впровадження НС-Р забезпечує ефективне управління мікрокліматом у силосах для зберігання борошна, підвищуючи якість продукції та оптимізуючи виробничі процеси.

Структурна схема розроблюваної системи наведена нижче на рисунку 2.7.



НР - нейромережевий регулятор; ДП - датчик збору параметрів технологічного процесу;
ОУ - об'єкт управління

Рисунок 2.7 - Структурна схема системи керування з використанням НС-Р

Висновки до розділу

У цьому розділі було розглянуто архітектуру нейромережевої системи регулювання (НС-Р), призначеної для управління мікрокліматом у силосах бестарного зберігання. Основою цієї системи є штучна нейронна мережа типу "багатошаровий персептрон" зі зворотним поширенням помилки, яка забезпечує високу адаптивність та ефективність регулювання. Розробка системи включала кілька етапів, зокрема аналіз автоматизованої системи управління технологічними процесами, вибір оптимальної архітектури

нейромережі, побудову бази даних для навчання системи та її інтеграцію в управлінське середовище.

Особливу увагу було приділено створенню бази даних, яка містить усі необхідні параметри: контрольовані, регульовані та збурювальні. Ця інформація є основою для навчання нейромережі та формування оптимальних керуючих впливів. Система дозволяє автоматично визначати оптимальні значення температури, вологості та концентрації CO₂ у силосах, що сприяє стабільності умов зберігання продукції та зменшує негативний вплив зовнішніх факторів.

НС-Р розроблена як універсальний інформаційно-обчислювальний комплекс, який може інтегруватися в існуючі SCADA-системи. Це забезпечує зручність експлуатації та підвищує ефективність управління технологічними процесами. Крім того, система може як надавати рекомендації оператору, так і автоматично управляти виконавчими механізмами, що робить її гнучкою в застосуванні.

Таким чином, запропонована нейромережева система є інноваційним підходом до автоматизації управління мікрокліматом у силосах, забезпечуючи стабільність зберігання продукції та підвищення ефективності технологічних процесів у харчовій промисловості.

РОЗДІЛ 3

ПРОГРАМНО-ТЕХНІЧНА РЕАЛІЗАЦІЯ СИСТЕМИ КЕРУВАННЯ ПРОЦЕСОМ

3.1 Відбір даних для навчання нейромережі

Для побудови ефективної нейронної мережі важливо правильно підготувати дані для навчання. Дані, наведені у таблиці 3.1, що моделюють температурні, вологісні та вмістові характеристики процесу (T_1 , T_2 , M , CO_{2_1} , CO_{2_2}), а також відповідні керуючі впливи (відсотки відкриття клапанів), є ключовими для створення моделі.

Таблиця 3.1 – Дані для навчання нейромережі

Позначення	Параметр
X_1	Температура всередині силоса, $T(t)$
X_2	Вологість повітря всередині силоса, $M(t)$
X_3	Вміст CO_2 у силосі, Q_{CO_2}
X_4	Температура зовнішнього повітря, $T_o(t)$
X_5	Вологість свіжого повітря, $M_a(t)$
X_6	Вміст CO_2 у вхідному повітрі, Q_{in}
X_7	Попереднє значення температури повітря всередині силоса, $T(t-1)$
X_8	Попереднє значення вологості повітря всередині силоса, $M(t-1)$
X_9	Кількість тепла за одиницю часу, що надходить від системи обігріву, $Q_{пот}$
X_{10}	Кількість свіжого повітря, що надходить у силос від системи вентиляції, $G_{вент}$
X_{11}	Витрата пари в системі зволоження в силосі, $G_{пар}(t)$
X_{12}	Температура повітря, що надходить у силос із борошном, $T_{бор}(t)$
X_{13}	Вологість повітря, що надходить у силос із борошном, $M_{бор}(t)$
X_{14}	Маса борошна, що знаходиться у силосі, $W_{бор}(t)$

Вихідні дані розраховані на основі формул, які описують ступінь відкриття клапанів залежно від вхідних параметрів:

1. Формула для клапана подачі тепла:

$$F^1 = 100 - \frac{T^1}{5} - \frac{T^2}{5}$$

де: F_1 — ступінь відкриття клапана для подачі тепла (у відсотках);

T_1 — температура повітря всередині приміщення;

T_2 — температура повітря ззовні.

2. Формула для клапана подачі пари:

$$F^2 = 100 - \frac{M}{2}$$

де: F_2 — ступінь відкриття клапана для подачі пари (у відсотках);

M — вологість повітря всередині приміщення.

3. Формула для клапана подачі свіжого повітря:

$$F^3 = 100 - \frac{CO_2(1)}{250} - \frac{CO_2(2)}{250}$$

де: F_3 — ступінь відкриття клапана для подачі свіжого повітря (у відсотках);

$CO_2(1)$ — концентрація вуглекислого газу всередині приміщення;

$CO_2(2)$ — концентрація вуглекислого газу ззовні.

Для навчання нейронної мережі будуть використані наступні вхідні параметри:

1. Температура повітря всередині приміщення (T_1);

2. Температура повітря ззовні (T_2);

3. Вологість повітря всередині приміщення (M);

4. Концентрація вуглекислого газу всередині приміщення ($CO_2(1)$);

5. Концентрація вуглекислого газу ззовні ($CO_2(2)$).

Вихідні параметри нейронної мережі:

1. F_1 — ступінь відкриття клапана для подачі тепла (у відсотках);

2. F_2 — ступінь відкриття клапана для подачі пари (у відсотках);

3. F_3 — ступінь відкриття клапана для подачі свіжого повітря (у відсотках).

На основі цих формул створюється навчальний набір даних (Таблиця 3.2), який включає 1000 прикладів. Ці приклади будуть використані для навчання нейронної мережі.

Таблиця 3.2 – Навчальний набір даних

№	T ₁ , °C	T ₂ , °C	M, %	CO ₂ (1), ppm	CO ₂ (2), ppm	1 клапан, %	2 клапан, %	3 клапан, %
1	42	41	46	773	846	32	77	83
2	45	32	45	782	977	43	77	79
3	50	26	46	822	916	48	77	81
4	29	34	48	755	952	60	76	81
5	30	45	41	763	907	66	80	80
...
996	43	45	46	744	908	60	79	81
997	45	40	46	780	958	48	79	80
998	39	34	46	709	916	68	80	79
1000	42	40	40	747	907	68	80	82

3.2 Алгоритм для навчання мережі та алгоритм роботи адаптивного керування системи

Алгоритм роботи системи, зображений на рисунку 3.1, передбачає дві основні стадії: навчання нейронної мережі та роботу системи з використанням навченої моделі. Спершу система активується, виконується початкова ініціалізація компонентів, а також налаштування зв'язку через OPC Toolbox для обміну даними. Вхідні параметри, такі як технологічні показники чи стан обладнання, надходять у форматі OPC для подальшого опрацювання.

На основі отриманих даних визначається режим роботи. Якщо система перебуває у режимі навчання, ініціалізуються ваги нейронної мережі малими значеннями, щоб уникнути перенавчання. Для навчання вибирається випадковий набір вхідних даних, які проходять через мережу в прямому напрямку, що дозволяє розрахувати прогнозовані вихідні параметри. Після цього виконується зворотний хід, під час якого похибка між прогнозованими

та еталонними значеннями використовується для коригування ваг. Значення градієнтного кроку обчислюється методом зворотного поширення помилки. Оновлення функції помилки здійснюється за допомогою спеціальної формули, яка дозволяє поступово зменшити похибку. Якщо функція помилки стабілізується, процес навчання завершується, і навчена модель зберігається.

Після завершення навчання система переходить у робочий режим, де на основі нових вхідних параметрів генеруються керуючі сигнали для об'єкта керування або рекомендації для оператора. Паралельно аналізується точність роботи моделі, що дозволяє забезпечити адаптацію до змін умов. Робота завершується після видачі сигналів, і система очікує на наступний цикл. Алгоритм побудований таким чином, щоб забезпечити надійну інтеграцію з реальним обладнанням через TIA Portal, використовуючи OPC Toolbox, що гарантує високу точність та адаптивність системи.

Алгоритм роботи системи оптимального керування(рис.3.2), передбачає інтеграцію даних із SCADA-системою, навчання нейронної мережі та її використання для розрахунку параметрів мікроклімату. Робота системи починається зі збору даних про функціонування SCADA-системи. Ця інформація передається в базу даних, де вона структурується для подальшого аналізу. Якщо інформація достатньо підготовлена, її передають у середовище симуляції, інакше продовжується оновлення бази даних.

Після структуризації починається етап налаштування роботи нейронної системи (НС). Система визначає, чи перебуває нейронна мережа в режимі навчання чи роботи. Якщо активується режим навчання, формується вектор даних для тренування. Далі розраховується функція помилки Q , яка оновлюється за допомогою заданої формули. Система перевіряє, чи досягнута похибка менше встановленого порогу.

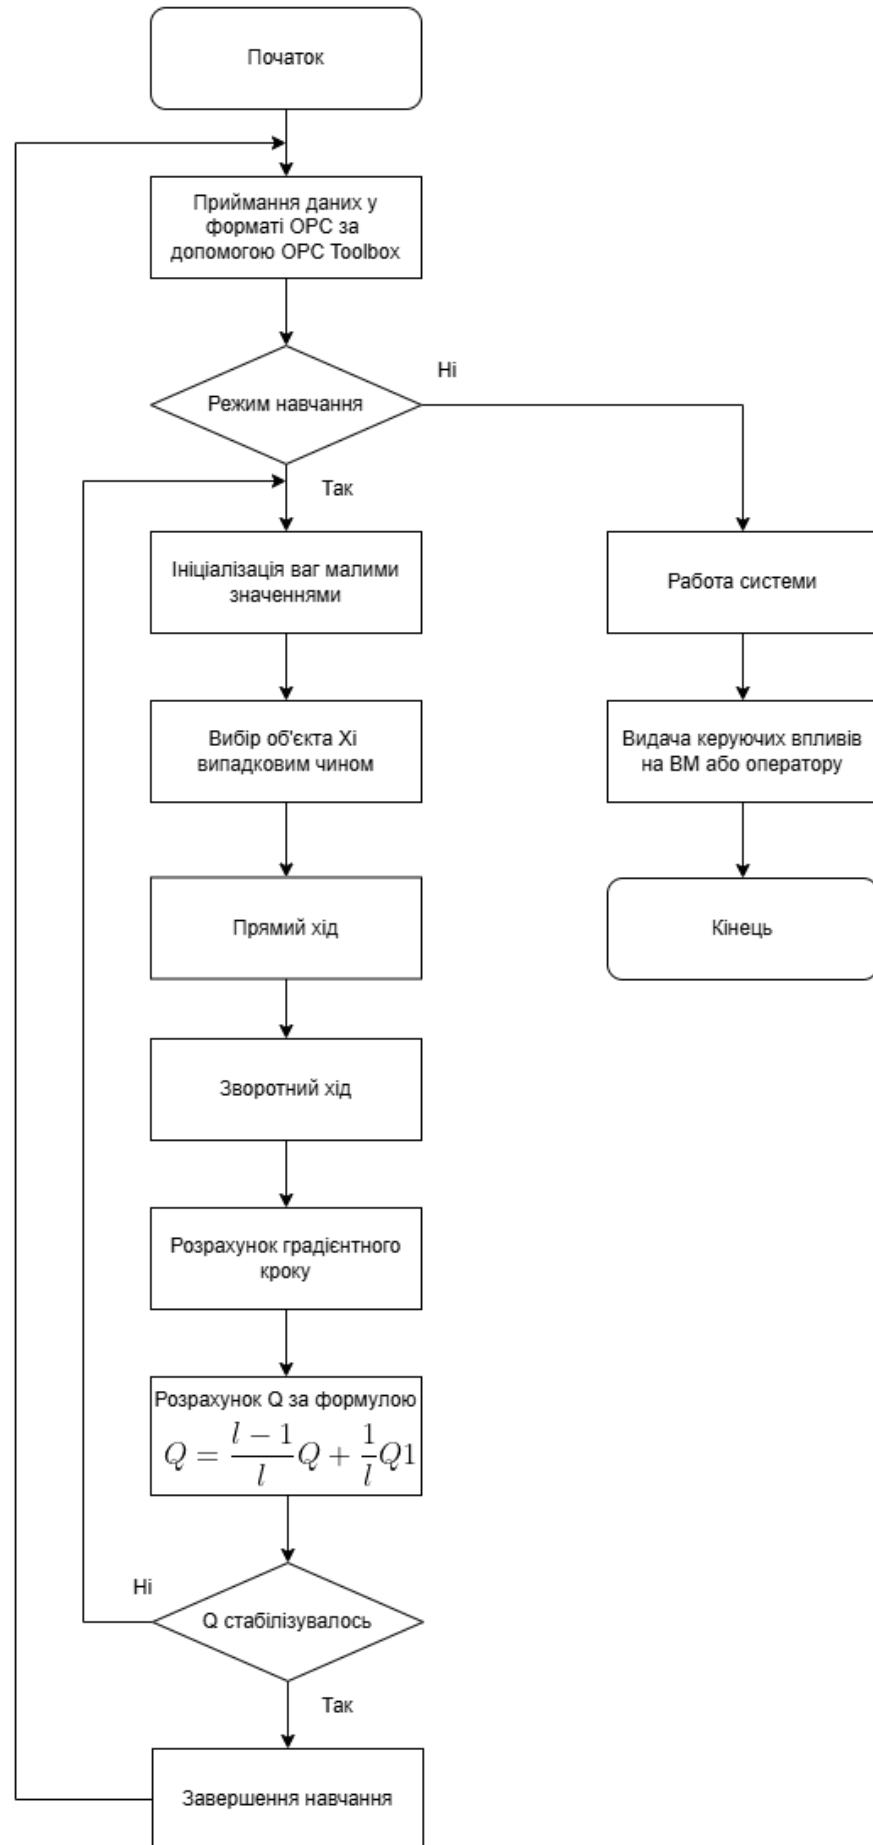


Рисунок 3.1 – Алгоритм роботи нейронної мережі

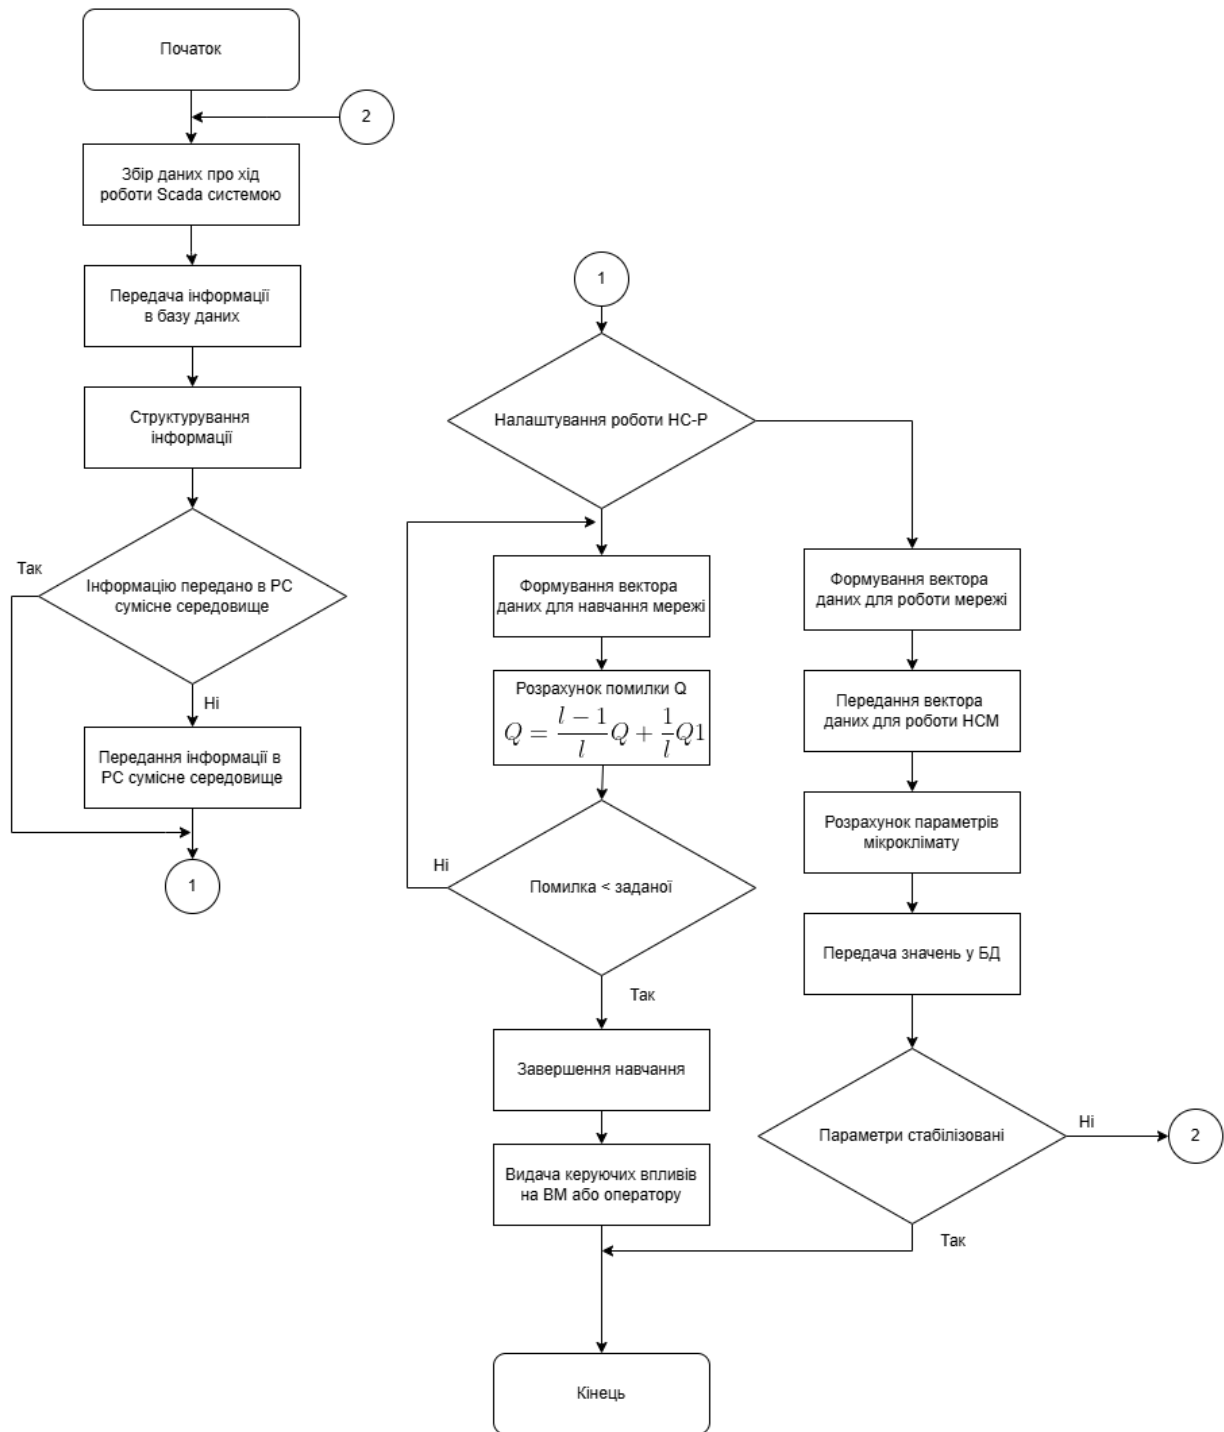


Рисунок 3.2 – Алгоритм роботи системи оптимального керування

Якщо умова виконується, навчання завершується, і результати використовуються для генерації керуючих впливів на виконавчі механізми або для видачі рекомендацій оператору. Якщо помилка перевищує допустиме значення, навчання продовжується з оновленими параметрами.

У режимі роботи нейронної мережі формується вектор даних, який передається на обробку НСМ (нейронною системою мікроклімату). Система виконує розрахунок параметрів мікроклімату та передає результати в базу даних. Водночас перевіряється стабільність параметрів. Якщо параметри стабілізовані, система повертається до збору даних із SCADA-системи. Інакше відбувається повторне передавання даних на симуляцію, і цикл продовжується.

Алгоритм завершується тоді, коли всі етапи стабільно виконані, і параметри системи досягли оптимальних значень. Це забезпечує точність і ефективність роботи системи в реальних умовах.

3.3 Програмна реалізація системи

MATLAB — це потужне середовище для розробки систем управління, яке забезпечує широкий функціонал для обробки даних, навчання нейронних мереж та моделювання в Simulink. Воно пропонує інструменти для виконання різноманітних завдань — від аналізу даних до створення складних фізичних моделей.

MATLAB чудово підходить для роботи з великими наборами даних, такими як навчальні вибірки (наприклад, із 1000 записів). Дані легко імпортуються з таких джерел, як Excel, CSV-файли чи бази даних, і можуть бути проаналізовані за допомогою зручних інструментів візуалізації. Це дозволяє ефективно підготувати дані для навчання нейронних мереж чи моделювання систем керування.

Для створення та навчання нейронних мереж MATLAB використовує Deep Learning Toolbox, який дозволяє реалізовувати різні архітектури, наприклад, багатошарові перцептрони. Нейронна мережа навчається на конкретному наборі параметрів (температура, вологість, концентрація CO₂) для визначення рівня відкриття клапанів. Після завершення навчання модель зберігається та інтегрується в Simulink для подальшого використання в моделюванні.

Simulink, як частина MATLAB, дозволяє будувати графічні моделі систем. У контексті цього завдання Simulink пропонує такі можливості, як створення блок-схем для моделювання роботи системи, інтеграція навченої нейронної мережі та реалізація залежностей між вхідними та вихідними параметрами.

Перед початком роботи імпортуємо файл із вхідними параметрами.

```
>> % Завантаження даних із файлу
data = simulatedtablenoheaders; % Імпортований файл у форматі table
```

Щоб конвертувати таблицю в числову матрицю, яку підтримують операції MATLAB було використано функцію `table2array(data)`.

```
% Конвертація таблиці в матрицю для обчислень
dataMatrix = table2array(data); % Перетворення на числову матрицю
```

Наша нейронна мережа складатиметься з двох шарів: прихованого шару та вихідного шару.

Перший крок – вибір структури нейронної мережі. Використовуватимемо двошарову однонаправлену мережу з сигмоїдальною активаційною функцією:

```
net = fitnet(hiddenLayerSize, trainFcn);
```

Далі необхідно вибрати кількість нейронів у прихованому шарі. В цьому випадку, експериментально встановлено, що оптимальне число нейронів у прихованому шарі дорівнює 48.

Навчання мережі здійснюватиметься за допомогою модифікованого алгоритму зворотного поширення помилки:

```
trainFcn = 'trainbr';
```

Потім налаштовуємо параметри навчання мережі, такі як максимальна кількість епох, кількість епох між показами результатів і критерій досягнення мети. Ці параметри підбираються експериментально, орієнтуючись на критерій завершення навчання.

Максимальна кількість епох навчання визначається як 1000:

```
net.trainParam.epochs = 1000;
```

Кількість епох між показами результатів встановимо рівним п'яти:

```
net.trainParam.show = 5;
```

Критерій досягнення мети, який вказує на допустиме значення помилки, за якого навчання вважається завершеним:

```
net.trainParam.goal = 0.0001;
```

Далі розділимо дані на три підмножини:

- навчальний набір (Training),
- перевірочний набір (Validation),
- тестовий набір (Testing).

Розподіл даних виконується наступним чином:

60% даних використовується для навчання,

35% – для перевірки,

5% – для тестування:

```
net.divideParam.trainRatio = 60/100;
```

```
net.divideParam.valRatio = 35/100;
```

```
net.divideParam.testRatio = 5/100;
```

```
% Розділення даних на вхідні (X) і вихідні (Y) параметри
X = dataMatrix(:, 1:5); % Вхідні параметри: T1, T2, M, CO2(1), CO2(2)
Y = dataMatrix(:, 6:8); % Вихідні параметри: F1, F2, F3

% Нормалізація вхідних даних
X_norm = normalize(X); % Нормалізація вхідних параметрів для покращення навчання

% Розподіл даних на навчальну, перевірочну та тестову вибірки
trainRatio = 60 / 100; % 60% даних для навчання
valRatio = 35 / 100; % 35% даних для перевірки
testRatio = 5 / 100; % 5% даних для тестування

% Кількість прикладів
numSamples = size(X, 1);

% Генеруємо індекси для поділу даних
[trainInd, valInd, testInd] = dividerand(numSamples, trainRatio, valRatio, testRatio);

% Створюємо набори даних для кожної вибірки
X_train = X_norm(trainInd, :); % Навчальні дані (входи)
Y_train = Y(trainInd, :); % Навчальні дані (виходи)

X_val = X_norm(valInd, :); % Перевірочні дані (входи)
Y_val = Y(valInd, :); % Перевірочні дані (виходи)

X_test = X_norm(testInd, :); % Тестові дані (входи)
Y_test = Y(testInd, :); % Тестові дані (виходи)
```

Рисунок 3.3 – Код для поділу даних

```

% Визначаємо структуру нейронної мережі
hiddenLayerSize = 48;           % Кількість нейронів у прихованому шарі
trainFcn = 'trainbr';           % Функція навчання (зворотне поширення помилки)

% Створюємо нейронну мережу
net = fitnet(hiddenLayerSize, trainFcn);

% Налаштовуємо параметри навчання
net.trainParam.epochs = 1000;   % Максимальна кількість епох
net.trainParam.show = 5;        % Інтервал відображення результатів (кожні 5 епох)
net.trainParam.goal = 0.0001;   % Критерій завершення навчання (точність)

% Налаштовуємо пропорції поділу даних
net.divideParam.trainRatio = trainRatio; % Доля даних для навчання
net.divideParam.valRatio = valRatio;     % Доля даних для перевірки
net.divideParam.testRatio = testRatio;   % Доля даних для тестування

% Навчаємо нейронну мережу
[net, tr] = train(net, X_train', Y_train');

% Перевіряємо результати навчання
Y_train_pred = net(X_train'); % Прогноз для навчальної вибірки
Y_val_pred = net(X_val');     % Прогноз для перевірконої вибірки
Y_test_pred = net(X_test');   % Прогноз для тестової вибірки

% Обчислюємо середньоквадратичну похибку (MSE) для кожної вибірки
mseTrain = mean((Y_train' - Y_train_pred).^2, 'all');
mseVal = mean((Y_val' - Y_val_pred).^2, 'all');
mseTest = mean((Y_test' - Y_test_pred).^2, 'all');

```

Рисунок 3.4 – Код для навчання мережі

```

% Виводимо результати MSE
disp(['MSE для навчальної вибірки: ', num2str(mseTrain)]);
disp(['MSE для перевірконої вибірки: ', num2str(mseVal)]);
disp(['MSE для тестової вибірки: ', num2str(mseTest)]);

% Візуалізація результатів
figure;
subplot(3, 1, 1);
plot(Y_test(:, 1), 'b', 'LineWidth', 1.5); hold on;
plot(Y_test_pred(1, :)', 'r--', 'LineWidth', 1.5);
title('Прогноз F1 (Тестова вибірка)');
legend('фактичне значення', 'Прогноз');
xlabel('Приклади');
ylabel('F1');

subplot(3, 1, 2);
plot(Y_test(:, 2), 'b', 'LineWidth', 1.5); hold on;
plot(Y_test_pred(2, :)', 'r--', 'LineWidth', 1.5);
title('Прогноз F2 (Тестова вибірка)');
legend('фактичне значення', 'Прогноз');
xlabel('Приклади');
ylabel('F2');

subplot(3, 1, 3);
plot(Y_test(:, 3), 'b', 'LineWidth', 1.5); hold on;
plot(Y_test_pred(3, :)', 'r--', 'LineWidth', 1.5);
title('Прогноз F3 (Тестова вибірка)');
legend('фактичне значення', 'Прогноз');
xlabel('Приклади');
ylabel('F3');

```

Рисунок 3.5 – Код для візуалізації результатів

Розраховані значення середньоквадратичної помилки для кожної вибірки наведено нижче на рис. 3.6.

```
MSE для навчальної вибірки: 4.563
MSE для перевіркової вибірки: 53.0856
MSE для тестової вибірки: 37.7101
```

Рисунок 3.6 – Розраховані значення

На рисунку 3.7 можна побачити структуру штучної нейронної мережі.

На вхід нейронної мережі подаються сигнали, які в нашому випадку включають такі параметри: температура повітря всередині приміщення, температура повітря зовні, вологість повітря всередині приміщення, концентрація вуглекислого газу всередині приміщення, а також концентрація вуглекислого газу зовні.

Кожен вхідний сигнал x_i підлягає обробці суматором, який виконує такі дії: множить кожен вхідний параметр x_i на відповідну вагу w , додає зміщення b , а потім сумує ці значення. Результат цієї операції є лінійною комбінацією вхідних сигналів і вагових коефіцієнтів.

Сума передається до функції активації, яка застосовується в кожному шарі нейронної мережі. Функція активації надає нелінійність моделі, що дозволяє мережі успішно розпізнавати складні залежності між вхідними параметрами та бажаними виходами. Для прихованого шару використовується, як правило, сигмоїдальна функція активації, яка зводить вихід до діапазону $[0, 1]$.

На виході нейронна мережа прогнозує три основні параметри:

1. Відсоток відкриття клапана для подачі пари – значення, яке визначає рівень відкриття клапана для регулювання подачі пари у систему.
2. Відсоток відкриття клапана для подачі тепла – регулює рівень подачі теплової енергії для підтримання комфортних умов у приміщенні.
3. Відсоток відкриття клапана для подачі свіжого повітря – значення, що забезпечує приплив зовнішнього повітря для вентиляції.

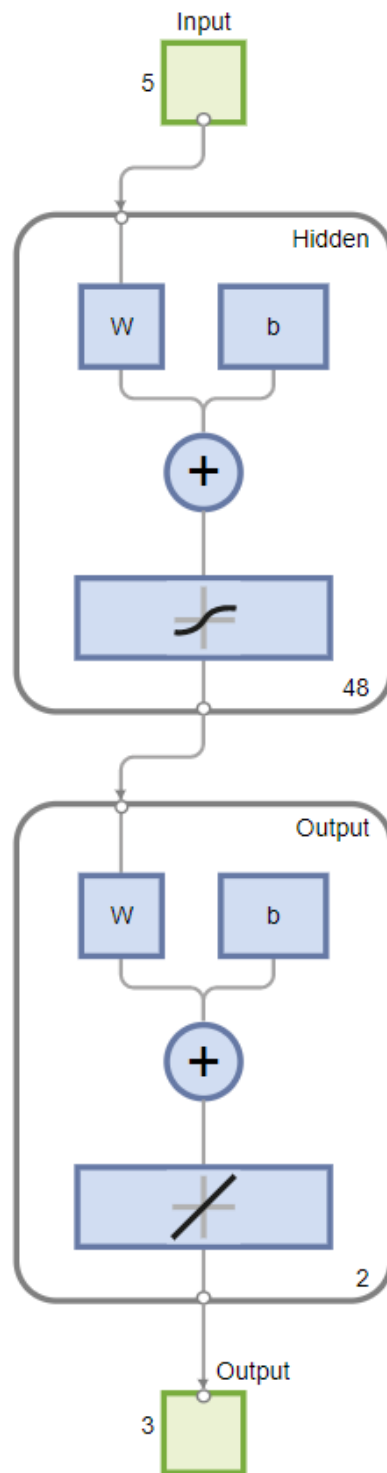


Рисунок 3.7 – Схема двошарової однонаправленої мережі з сигмоїдальною активаційною функцією

Цей процес моделює реальну систему управління, в якій враховується комплекс вхідних даних для визначення оптимальних параметрів управління. Завдяки структурі нейронної мережі, яка включає ваги, зміщення та функцію

активації, мережа здатна адаптуватися до складних і нелінійних взаємозв'язків між входами та виходами.

Крім того, завдяки попередньому навчанню на великій кількості даних (у нашому випадку 990 прикладів), мережа може швидко й точно реагувати на зміну умов у реальному часі. Це робить її ефективним інструментом для автоматизації процесів у сучасних системах управління.

Всі отримані значення і налаштування можна побачити на рис.3.8.

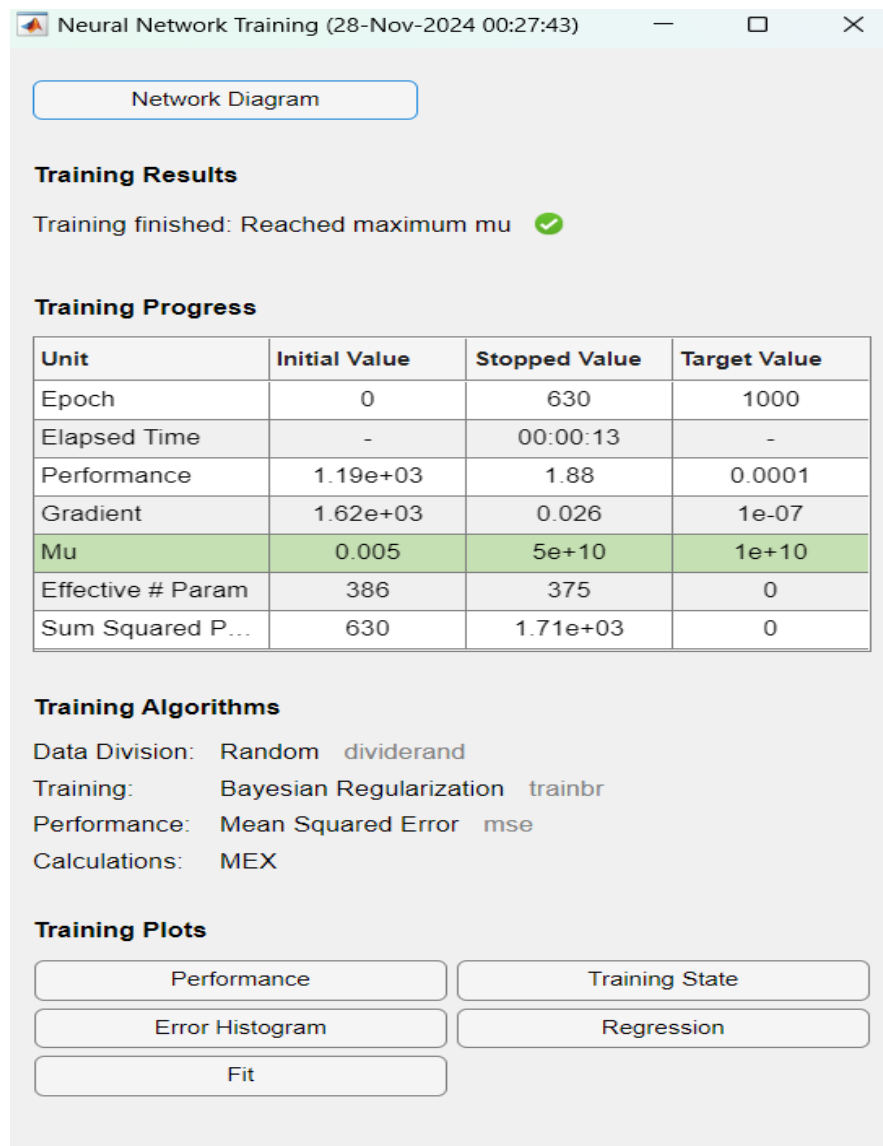


Рисунок 3.8 – Налаштування і параметри мережі

У процесі навчання нейронної мережі в MATLAB користувач має можливість проаналізувати ефективність навчання, скориставшись кнопкою

Performance у вікні навчання мережі. Після натискання на цю кнопку відображається графік продуктивності, який ілюструє зміну значення помилки під час навчання.

На графіку можна побачити поведінку помилки для різних наборів даних: навчального, валідаційного та тестового. Ці криві дозволяють оцінити, наскільки добре нейронна мережа узгоджується з вхідними даними. Наприклад:

- *Крива помилки навчання* демонструє, як швидко мережа адаптується до навчального набору даних. Її зменшення вказує на ефективне навчання.

- *Крива помилки валідації* показує, як добре мережа узагальнює результати на даних, які не використовувалися безпосередньо в навчанні. Зростання цієї помилки може свідчити про перенавчання.

- *Крива помилки тестування* вказує на продуктивність мережі при роботі з новими, невідомими даними.

Крім цього, на графіку можна побачити точку, в якій навчання було зупинено, якщо мережа досягла оптимального значення помилки або завершила навчання за встановленими критеріями, наприклад, за кількістю епох чи досягненням мети (goal).

З аналізу графіків, представлених на рисунку 3.9, видно, що помилка для навчального набору поступово зменшується і наближається до мінімального значення, тоді як помилка для тестового набору зростає незначно. Після 1000 епох навчання остаточне значення середньоквадратичної помилки досягло величини $1,1476 \times 10^{-9}$, що є надзвичайно малим. Такий результат свідчить про високий рівень точності й ефективності навчання нейронної мережі для управління параметрами мікроклімату.

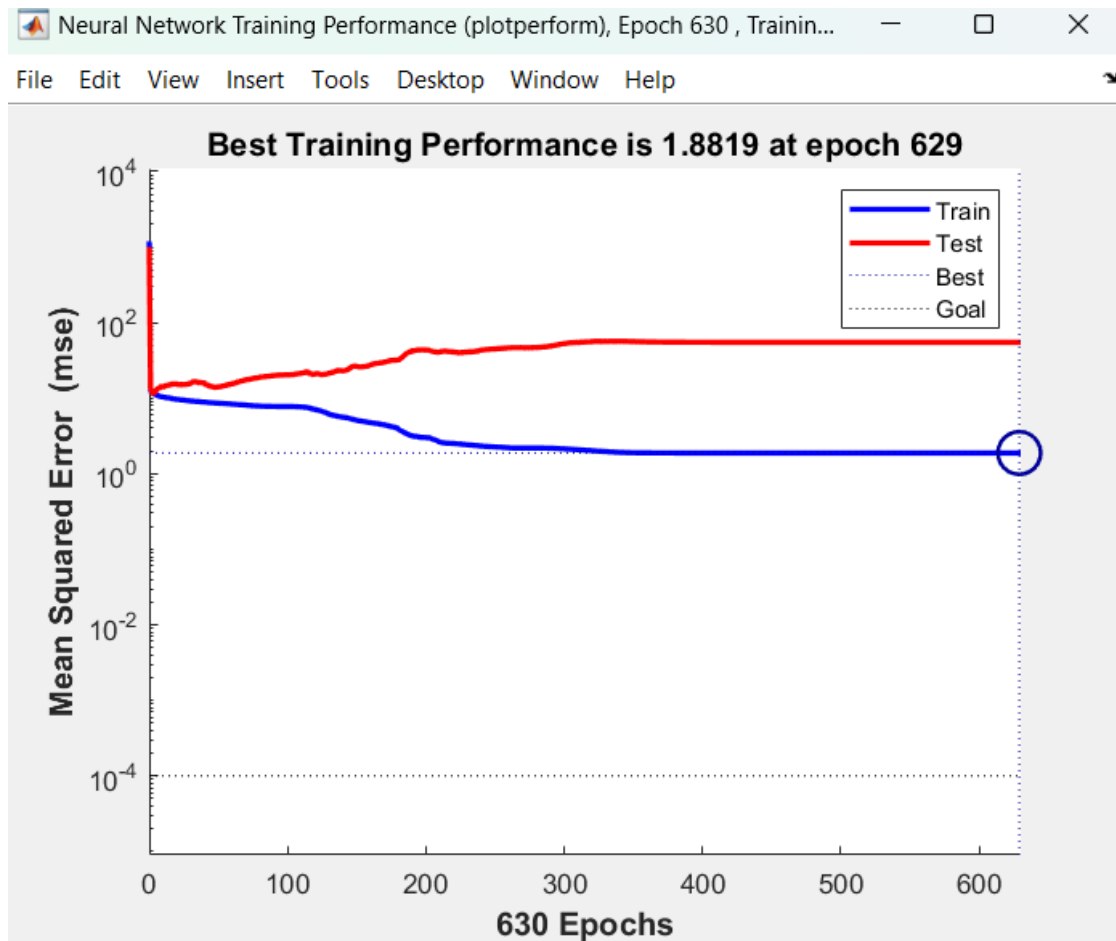


Рисунок 3.9 - Ефективність навчання

Цей результат демонструє, що мережа успішно навчилася знаходити залежності між вхідними даними (температура, вологість, концентрація вуглекислого газу) та вихідними параметрами (ступінь відкриття клапанів). Невелике значення середньоквадратичної помилки вказує на те, що модель здатна забезпечувати точне управління системою, навіть для даних, яких вона раніше не "бачила".

Графік на рисунку 3.9 також дозволяє оцінити динаміку процесу навчання. Зокрема:

- Помітно, що навчальна помилка зменшується стабільно протягом усього процесу, що свідчить про правильний вибір архітектури мережі та алгоритму навчання.

– Відсутність різких коливань або значного зростання тестової помилки свідчить про те, що модель не перенавчилася і зберегла здатність до узагальнення.

Такий рівень продуктивності нейронної мережі підтверджує її готовність до впровадження в реальну систему автоматизованого управління мікрокліматом. Це дозволить забезпечити оптимальні умови в приміщенні, знижуючи витрати енергії та підвищуючи комфортність середовища.

Також важливим параметром для оцінки роботи нейронної мережі є регресія, графік якої наведено на рисунку 3.10.

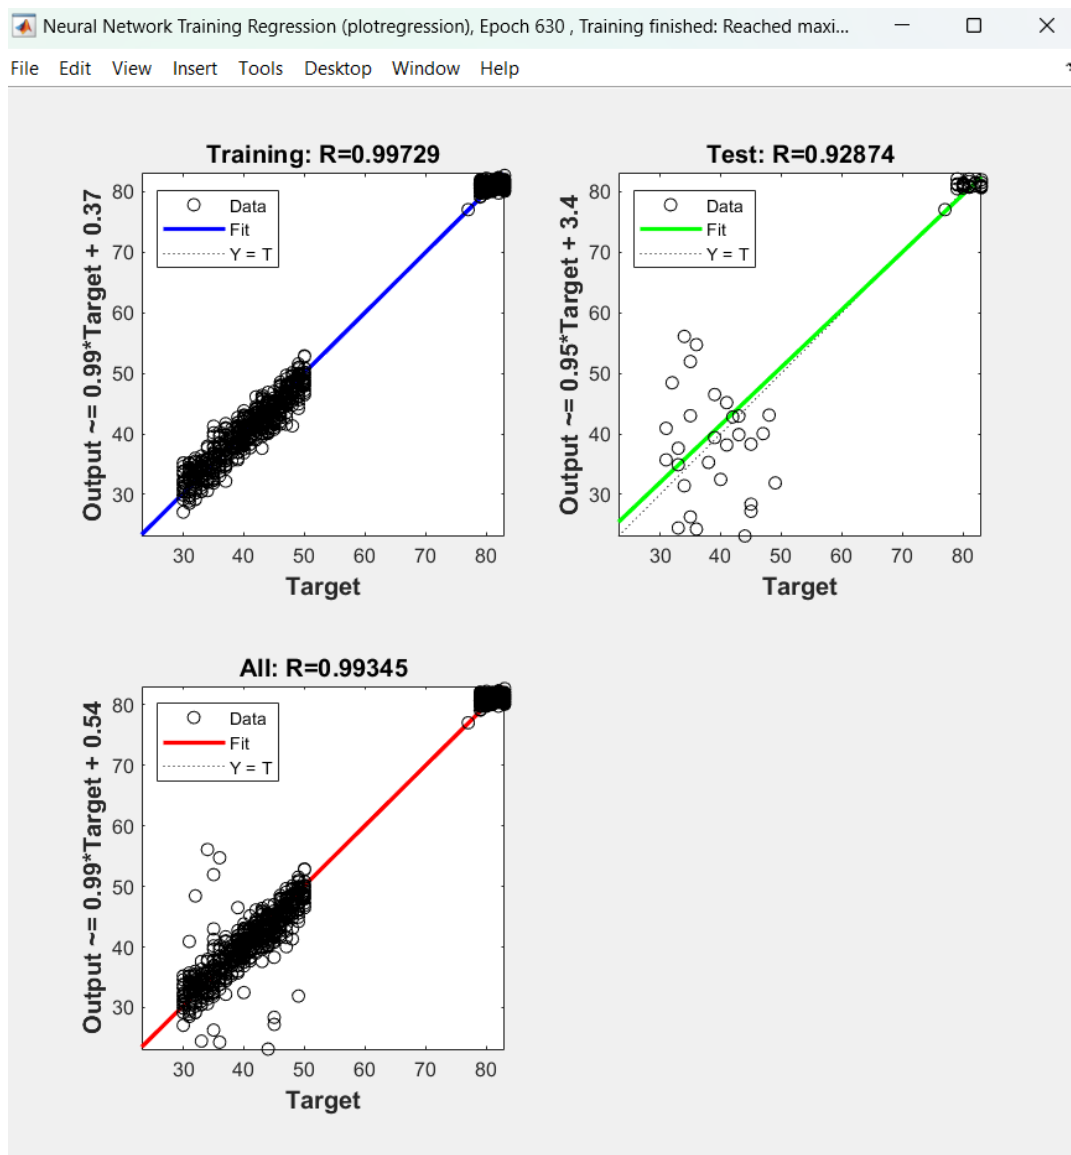


Рисунок 3.10 – Регресія для всіх трьох вибірок

Коефіцієнт кореляції R , який у нашому випадку становить 0.99729, 0.92874 та 0.99345, вказує на сильний зв'язок між вхідними та вихідними змінними. Це свідчить про високу точність та ефективність навченої нейронної мережі. Високе значення коефіцієнта кореляції демонструє, що модель добре узгоджується з реальними даними і здатна точно прогнозувати вихідні параметри системи.

Графіки регресії дозволяють оцінити рівень відповідності прогнозованих значень тим, які фактично спостерігалися під час тестування. Лінія регресії, близька до діагоналі (де прогнозовані значення збігаються з фактичними), підтверджує, що нейронна мережа ефективно справляється зі своїм завданням. Це ще раз підкреслює, що побудована модель є оптимальною для управління параметрами мікроклімату.

Розглянемо графіки, що відображають динаміку навчання нейронної мережі, представлені на рисунку 3.11.

На першому графіку можна спостерігати значення градієнта, яке є ключовим показником ефективності навчання. Чим ближче значення градієнта до нуля, тим більш стабільним і точним є процес навчання та тестування моделі.

Графік «validation» демонструє зміну помилки на перевірочному наборі даних. Цей показник відображає здатність моделі адаптуватися до нових даних, не втрачаючи точності. Низьке значення помилки на контрольному множині підтверджує високий рівень узагальнення моделі.

Графік « μ » ілюструє зміну коефіцієнта навчання μ , що використовується в алгоритмі байєсової регуляризації. Зростання цього параметра вказує на те, що модель стає більш точною в процесі навчання. Це важливий показник, який підтверджує, що обраний алгоритм дозволяє забезпечити високу якість роботи нейронної мережі.

Num Parameters (Кількість параметрів) – цей графік демонструє, як змінюється кількість параметрів моделі впродовж навчання. Збільшення кількості параметрів свідчить про те, що мережа адаптується до навчальних

даних, додаючи нові вагові коефіцієнти, необхідні для точнішої побудови моделі.

Sum Squared Param (Сума квадратів параметрів) – цей графік відображає зміну суми квадратів усіх параметрів мережі під час навчання. Його збільшення є свідченням активної модифікації вагових коефіцієнтів, що вказує на ефективний процес оптимізації мережі. Стабілізація цього показника може означати досягнення оптимальної конфігурації моделі.

Ці графіки є основою для оцінки процесу навчання, допомагаючи визначити якість адаптації мережі до вхідних даних і її здатність узагальнювати результати.




Рисунок 3.11 – Динаміка навчання

Під час навчання нейронної мережі ми отримали можливість прогнозувати вихідні параметри системи керування мікрокліматом. На

зображенні 3.12 представлені результати прогнозування роботи клапанів системи на тестовій вибірці. Аналіз отриманих графіків дозволяє оцінити точність прогнозів для кожного вихідного параметра та зробити висновки про ефективність моделі.

Для першого параметра, який визначає відсоток відкриття клапана на подачу тепла, спостерігається висока точність прогнозування. Прогнозовані значення (синя лінія) майже повністю збігаються з фактичними (червона пунктирна лінія). Незначні відхилення можуть бути пов'язані з похибками вимірювань або характеристиками тестової вибірки, але вони не впливають на загальну відповідність. Така точність демонструє, що модель успішно адаптована до розпізнавання закономірностей у даних для цього параметра.

Другий параметр, який відображає відсоток відкриття клапана на подачу пари, має майже стабільний графік прогнозів. Це може свідчити про те, що під час навчання модель отримала дані з низькою варіативністю, що ускладнило врахування можливих коливань у роботі системи. Незважаючи на це, прогноз досить точний для стабільних умов, що підтверджує адекватність моделі для більшості реальних сценаріїв експлуатації.

Третій параметр, що відповідає за відсоток відкриття клапана на подачу свіжого повітря, також показує хорошу відповідність між фактичними та прогнозованими значеннями. Хоча іноді спостерігаються певні відхилення, загальна динаміка змін передається точно. Це свідчить про те, що модель ефективно виявляє закономірності для цього параметра та здатна прогнозувати його поведінку навіть за умов коливань у вхідних даних.

Загалом результати моделювання підтверджують високу якість навчання нейронної мережі. Прогнозування вихідних параметрів системи мікроклімату демонструє, що модель здатна передбачати роботу клапанів із прийнятною точністю. Це дозволяє інтегрувати таку систему у реальну практику керування мікрокліматом, забезпечуючи ефективне керування температурою, вологістю та подачею свіжого повітря. Водночас деякі відхилення, виявлені у прогнозах, можуть слугувати основою для подальшого вдосконалення моделі, наприклад,

шляхом використання більш обширного набору даних для навчання або застосування інших алгоритмів оптимізації.

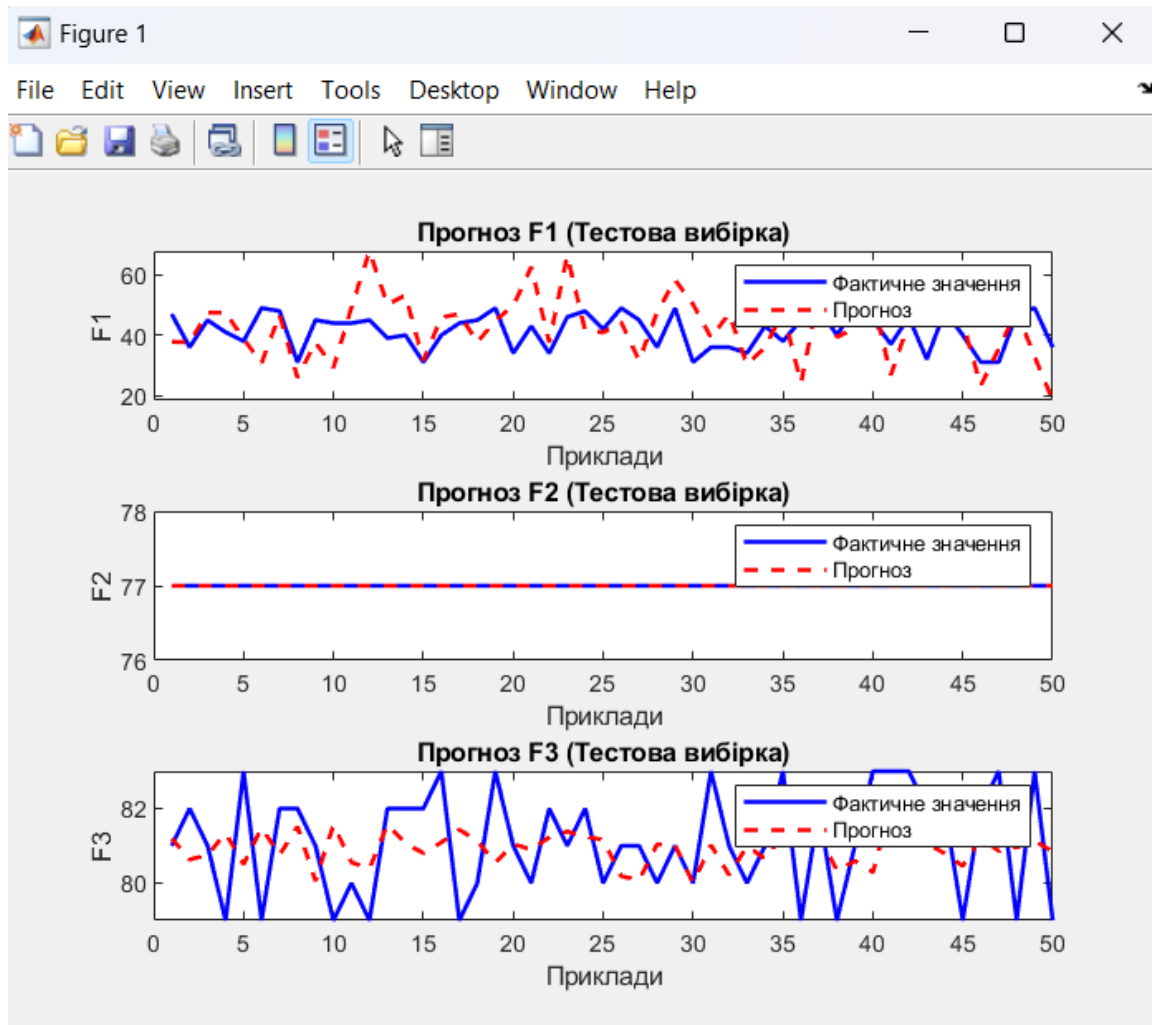


Рисунок 3.12 – Результати прогнозування

Тепер зберігаємо нашу нейронну мережу для подальшої побудови SIMULINK моделі, яка буде з'єднуватися через OPC UA з TIA Portal для регулювання параметрів безпосередньо з НМІ.

```

% Вкажіть ім'я файлу для збереження
fileName = 'trained_network.mat';

% Збереження нейронної мережі у файл
save(fileName, 'net');

% Повідомлення про успішне збереження
disp(['Мережу успішно збережено у файл: ', fileName]);
Мережу успішно збережено у файл: trained_network.mat

```

Рисунок 3.12 – Збереження мережі

Для подальшої роботи нашої системи створюємо OPC UA сервер.

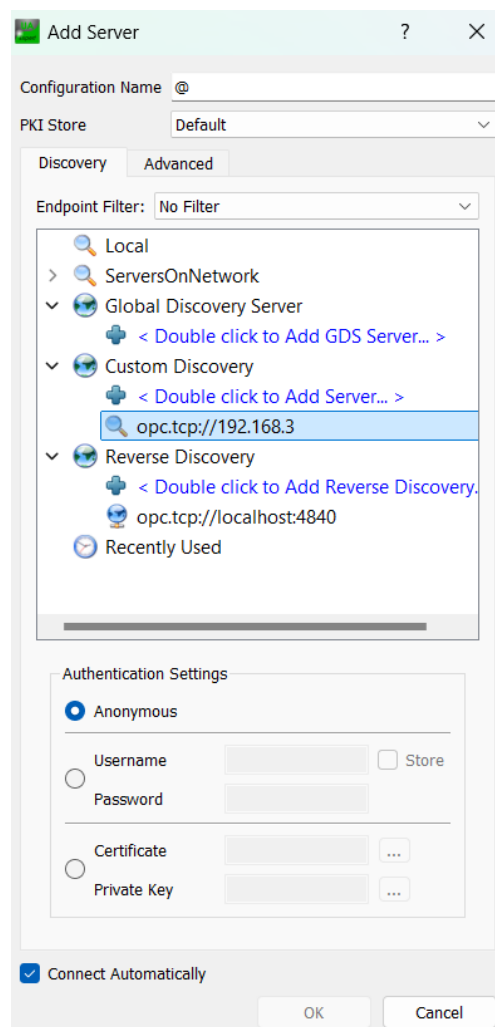


Рисунок 3.12 – Створення серверу для зв'язку

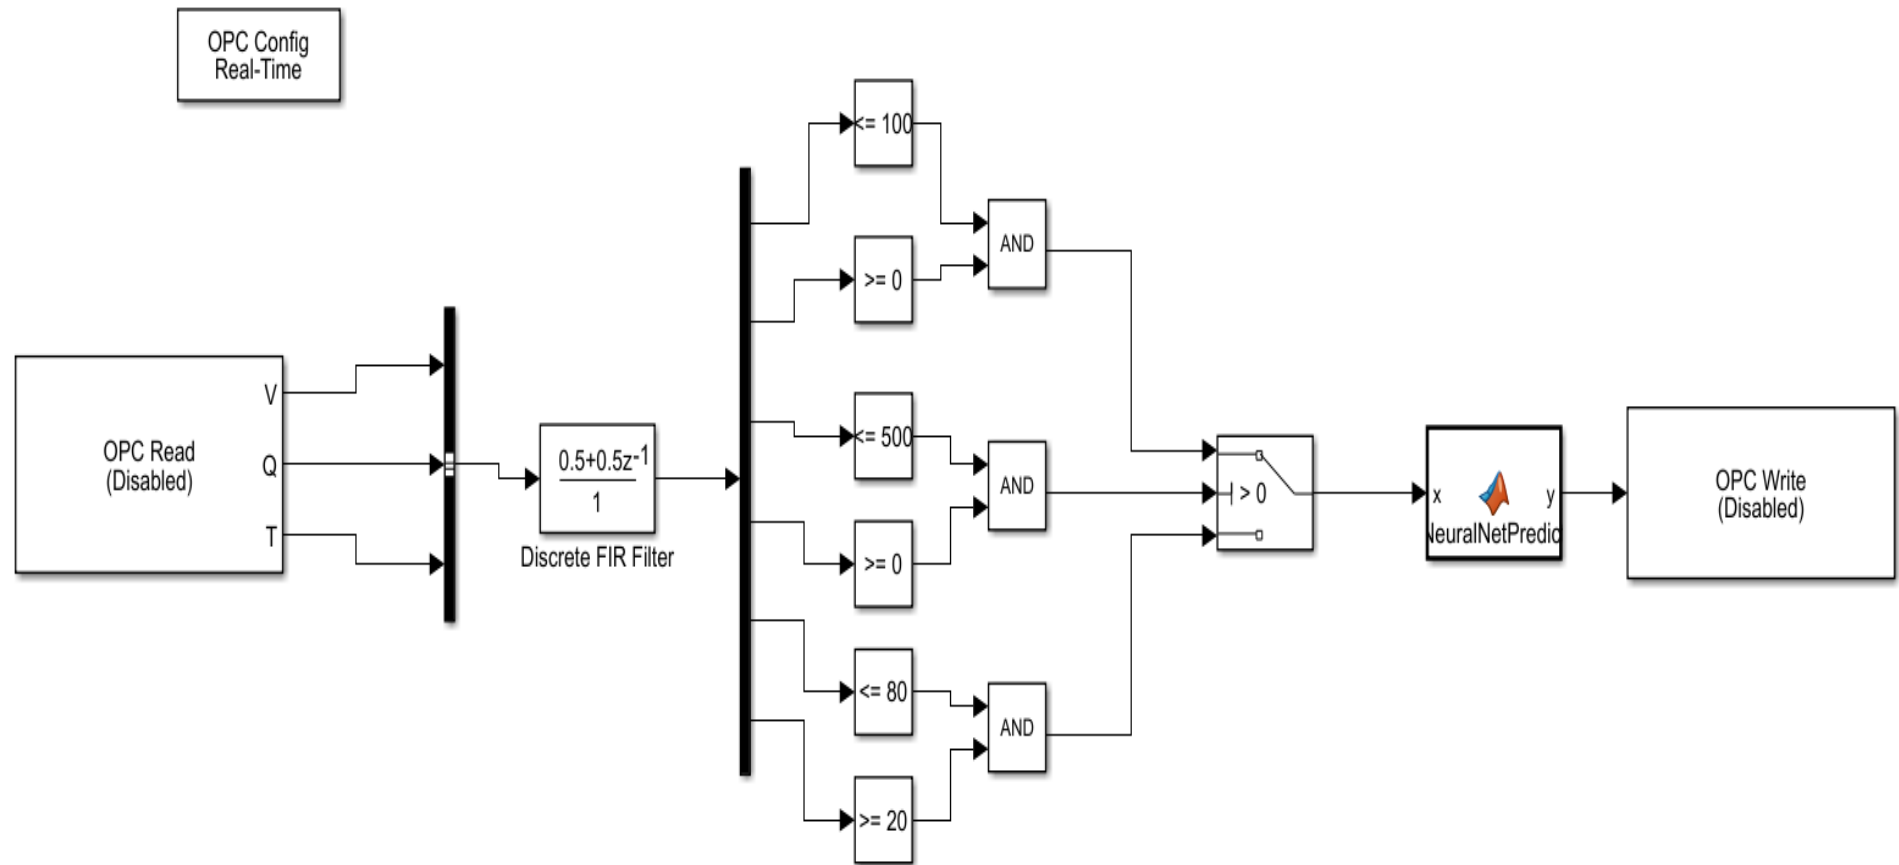


Рисунок 3.13 – Реалізована схема у Simulink

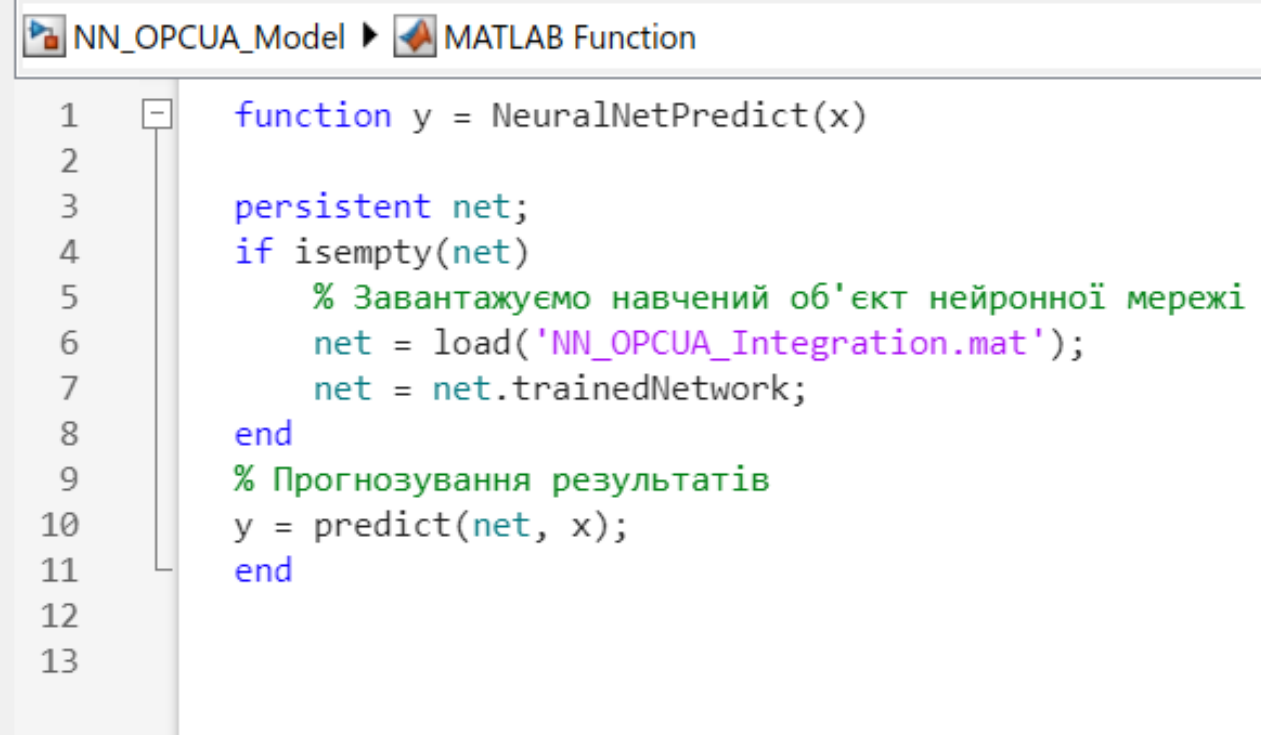
Ця схема представляє систему обробки та перевірки сигналів у реальному часі з використанням OPC-сервера, фільтрації, перевірки валідності та подальшої обробки нейронною мережею. На першому етапі сигнали (позначені як V, Q, T) зчитуються через блок OPC Read, який отримує дані з OPC-сервера. Потім ці сигнали об'єднуються і передаються на дискретний FIR-фільтр, що застосовується для зменшення шумів і покращення якості сигналів.

Після фільтрації сигнали розділяються на окремі гілки, де кожна проходить перевірку на відповідність визначеним діапазнам значень. Для цього використовуються блоки порівняння, що перевіряють верхні та нижні межі для кожного сигналу. Наприклад, для сигналу V перевіряється, чи значення не перевищує 100 і не менше 0, аналогічно перевіряються сигнали Q і T з відповідними межами. Логічні блоки AND об'єднують результати перевірок кожного сигналу, щоб підтвердити їхню валідність.

Далі всі перевірки зводяться в один сигнал через логічний блок, який визначає, чи всі сигнали знаходяться в допустимих межах. Якщо сигнали валідні, вони передаються в нейронну мережу NeuralNetPredict для прогнозування. Якщо хоча б один сигнал виходить за межі, система перемикається на інший механізм обробки або аварійний режим.

Результати обробки передаються до блоку OPC Write, який відправляє їх назад на OPC-сервер для подальшого використання. Схема також має гнучку архітектуру, що дозволяє легко адаптувати перевірки або обробку під конкретні вимоги.

На рисунку 3.14 наведено код функціонального блоку для роботи з навченою нейромережею, який виступає основою для прогнозованого керування.



```

1  function y = NeuralNetPredict(x)
2
3  persistent net;
4  if isempty(net)
5      % Завантажуємо навчений об'єкт нейронної мережі
6      net = load('NN OPCUA_Integration.mat');
7      net = net.trainedNetwork;
8  end
9  % Прогнозування результатів
10 y = predict(net, x);
11 end
12
13

```

Рисунок 3.14 – Код функціонального блоку

У даній схемі TIA Portal виступає як ключовий елемент управління і комунікації між фізичними пристроями, такими як сенсори і виконавчі механізми, та обчислювальним середовищем MATLAB/Simulink. Ця система реалізує інтеграцію між апаратним і програмним рівнями за допомогою протоколу OPC UA, що забезпечує передачу даних у реальному часі та двонаправлений обмін інформацією.

Рисунок 3.15 показує інтерфейс програмного забезпечення TIA Portal, який демонструє налаштування контролера Siemens S7-1200 та активацію OPC UA-сервера для інтеграції з іншими системами.

На панелі Properties у нижній частині екрана показані налаштування сервера OPC UA. У розділі General включено опцію Activate OPC UA server, що означає активацію OPC UA-сервера для обміну даними між контролером і зовнішніми клієнтами. Також у полі Server addresses вказано IP-адресу сервера (192.168.0.1) і порт (4840), які використовуються для підключення до серверу. Ця інформація необхідна для конфігурації клієнта OPC UA.

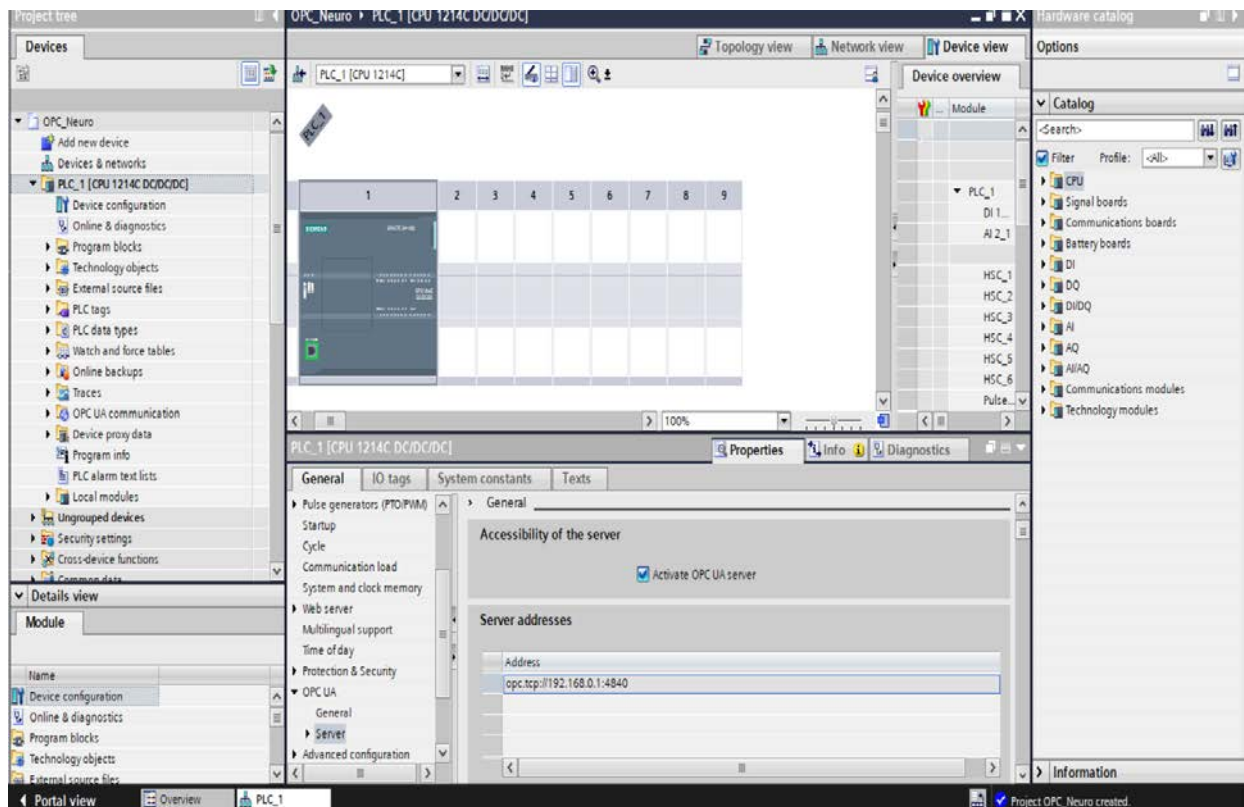


Рисунок 3.15 – Налаштування сервера OPC UA

Далі переходимо до конфігурації змінних (tags) у середовищі TIA Portal для контролера Siemens S7-1200. Ця вкладка використовується для створення, редагування та управління тегами, які відповідають змінним, що застосовуються в програмі ПЛК та інтегруються з іншими системами.

Змінні Tin, Tout, CO2 та Humidity використовуються для передачі значень температури, рівня вуглекислого газу та вологості, а логічні теги для управління клапанами або вибору режимів роботи.

Ця таблиця є ключовим інструментом для організації змінних, що використовуються для обміну даними між контролером та зовнішніми системами, такими як OPC UA клієнти.

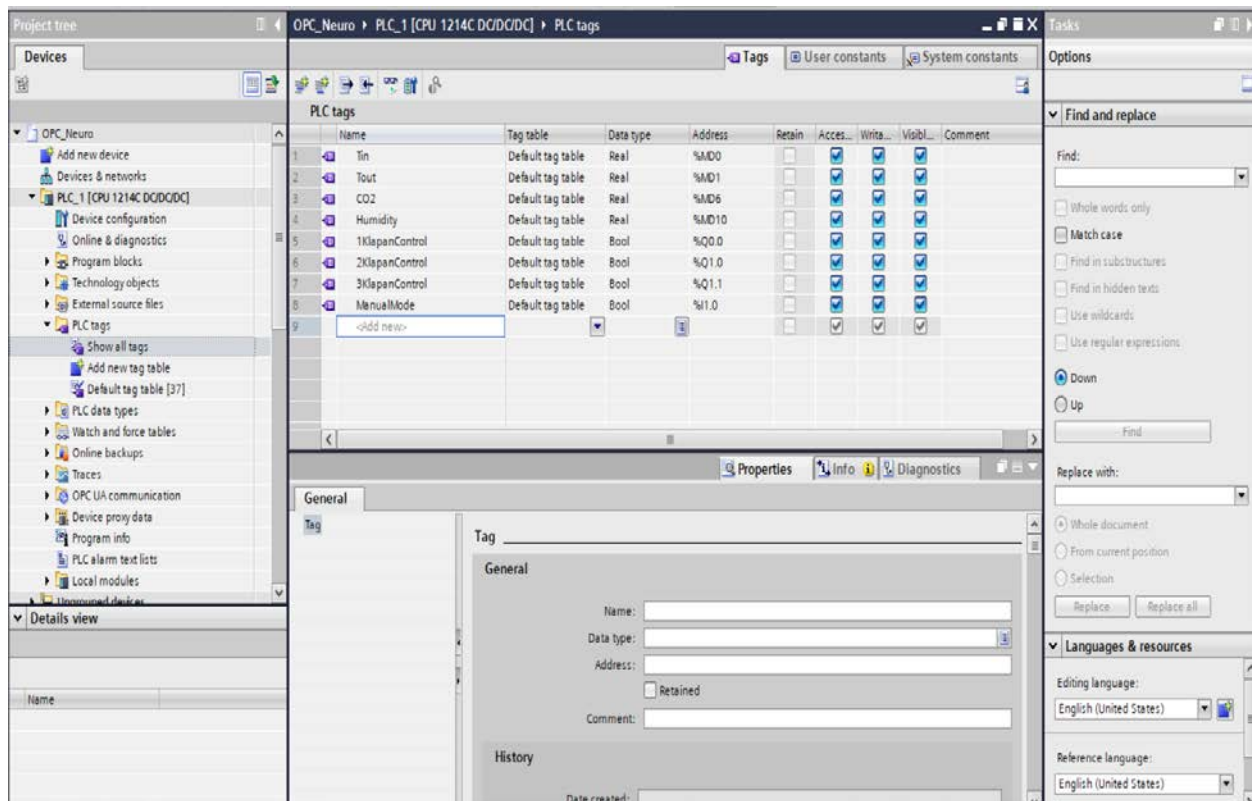


Рисунок 3.16 – Конфігурація змінних

На рисунку 3.17 зображено вкладку Program blocks у середовищі TIA Portal, де відображено основну програму контролера (Main [OB1]) для реалізації логіки управління.

У Network 1 реалізовано виклик функціонального блоку FC1 під назвою "OPC-UA Data". Цей блок відповідає за обробку або передачу даних між контролером і OPC UA сервером, забезпечуючи інтеграцію з зовнішніми системами, код якого наведено нижче.

```

FUNCTION_BLOCK "OPC UA Data"
TITLE = "Блок прийому даних через OPC UA"
VERSION : 0.1

VAR
    Tin : REAL; // Температура на вході
    Tout : REAL; // Температура на виході

```

```
CO2 : REAL; // Рівень CO2
Humidity : REAL; // Вологість
Klapan1Control : BOOL; // Управління клапаном 1
Klapan2Control : BOOL; // Управління клапаном 2
Klapan3Control : BOOL; // Управління клапаном 3
ManualMode : BOOL; // Ручний режим
END_VAR

BEGIN
    // Прийом значень через OPC UA
    Tin := OPC-UA_Read("ns=2;s=Tin");      // Читаємо температуру на
вході
    Tout := OPC-UA_Read("ns=2;s=Tout");    // Читаємо температуру на
виході
    CO2 := OPC-UA_Read("ns=2;s=CO2");      // Читаємо рівень CO2
    Humidity := OPC-UA_Read("ns=2;s=Humidity"); // Читаємо вологість

    // Прийом стану клапанів і режиму
    Klapan1Control := OPC-UA_Read("ns=2;s=Klapan1Control"); // Стан
клапана 1
    Klapan2Control := OPC-UA_Read("ns=2;s=Klapan2Control"); // Стан
клапана 2
    Klapan3Control := OPC-UA_Read("ns=2;s=Klapan3Control"); // Стан
клапана 3
    ManualMode := OPC-UA_Read("ns=2;s=ManualMode"); // Ручний
режим

END_FUNCTION_BLOCK
```

У Network 2 здійснюється виклик функціонального блоку FB1 із назвою "Control data". Використання блоку DB1 як екземпляра функціонального блоку вказує на те, що цей блок містить інформацію про стан системи, зокрема, дані управління чи стан пристроїв, необхідні для роботи контролера. Вхідні параметри EN та ENO відображають активність і вихідний статус виклику цього блоку.

```
FUNCTION_BLOCK "Control Data"
```

```
TITLE = "Блок управління клапанами силоса"
```

```
VERSION : 0.1
```

```
VAR
```

```
    Klapan1Control : BOOL; // Управління клапаном 1
```

```
    Klapan2Control : BOOL; // Управління клапаном 2
```

```
    Klapan3Control : BOOL; // Управління клапаном 3
```

```
    Klapan1State : BOOL; // Стан клапана 1
```

```
    Klapan2State : BOOL; // Стан клапана 2
```

```
    Klapan3State : BOOL; // Стан клапана 3
```

```
    ErrorFlag : BOOL; // Ознака помилки
```

```
END_VAR
```

```
BEGIN
```

```
    // Управління клапаном 1
```

```
    IF Klapan1Control THEN
```

```
        // Якщо управління активовано, відкриваємо клапан 1
```

```
        Klapan1State := TRUE; // Клапан 1 відкрито
```

```
    ELSE
```

```
        Klapan1State := FALSE; // Клапан 1 закрито
```

```
    END_IF;
```

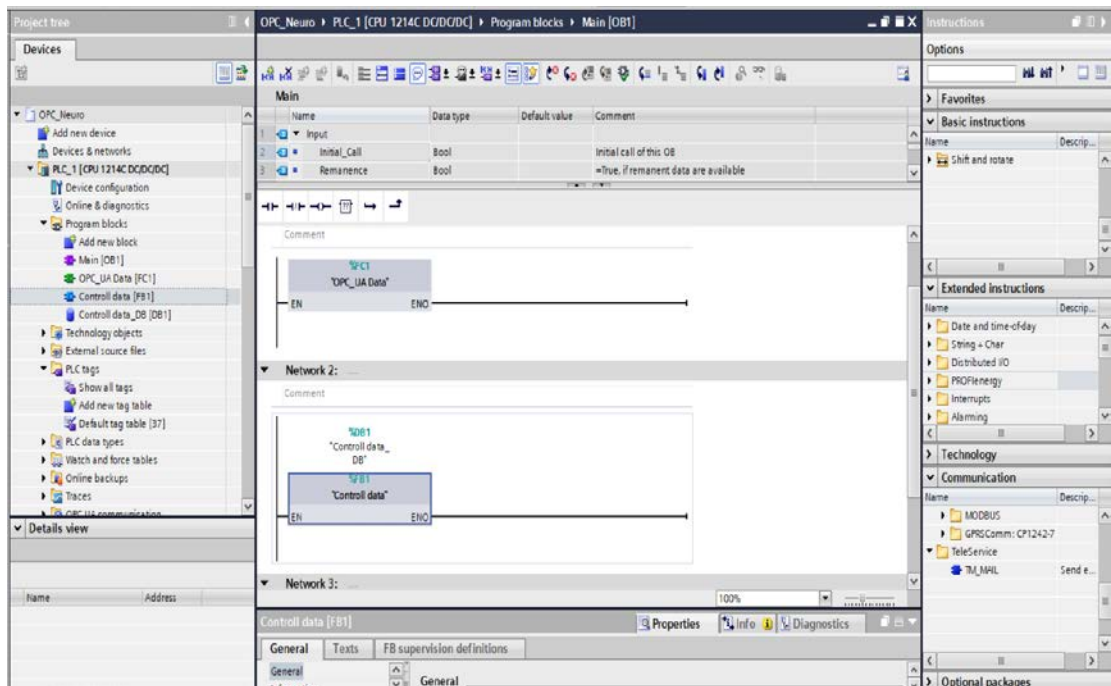
```
    // Управління клапаном 2
```

```
IF Klapan2Control THEN
    // Якщо управління активовано, відкриваємо клапан 2
    Klapan2State := TRUE; // Клапан 2 відкрито
ELSE
    Klapan2State := FALSE; // Клапан 2 закрито
END_IF;

// Управління клапаном 3
IF Klapan3Control THEN
    // Якщо управління активовано, відкриваємо клапан 3
    Klapan3State := TRUE; // Клапан 3 відкрито
ELSE
    Klapan3State := FALSE; // Клапан 3 закрито
END_IF;

// Перевірка можливих конфліктів або помилок
IF (Klapan1Control AND Klapan2Control) OR
   (Klapan1Control AND Klapan3Control) OR
   (Klapan2Control AND Klapan3Control) THEN
    // Якщо одночасно активні більше одного клапана
    ErrorFlag := TRUE; // Встановлюємо ознаку помилки
ELSE
    ErrorFlag := FALSE; // Помилки немає
END_IF;

// CallOutput(Klapan1State, Klapan2State, Klapan3State);
END_FUNCTION_BLOCK
```



3.17 - Program blocks

Завершальним етапом нашої системи є інтерфейс оператора НМІ (Human-Machine Interface), який створений у середовищі SIMATIC НМІ (рис.3.18). Інтерфейс призначений для моніторингу та керування технологічним процесом.

Режим роботи системи визначається блоком "Manual mode", де розміщено перемикач, який дозволяє змінювати ручний або автоматичний режим роботи. Зараз система перебуває в ручному режимі, що позначено статусом "OFF".

На екрані відображаються індикатори стану трьох клапанів. Перший клапан має зелений індикатор, що свідчить про його активний стан, тоді як другий і третій клапани позначені червоними індикаторами, які вказують на неактивний або аварійний стан.

У центральній частині екрана знаходиться графік трендів, який відображає зміни параметрів у часі. Графік супроводжується часовими мітками у форматі "години:хвилини:секунди", а також має функції керування, такі як прокрутка, збільшення масштабу, пауза і перегляд подій.

На правій стороні екрана розташовані аналогові шкали, які показують значення ключових параметрів системи: вхідної температури (T_{in}), вихідної температури (T_{out}) та вологості (Humidity). Вхідна та вихідна температури мають діапазон від -20 до 100 градусів, а вологість вимірюється у відсотках від 0 до 100%. Поточні значення відображаються за допомогою покажчиків на шкалах.

Цей HMI-інтерфейс дозволяє оператору контролювати параметри температури та вологості, моніторити стан клапанів, а також вибирати режими роботи системи. Інтерфейс передбачає інтеграцію з SCADA-системою через відповідні протоколи, такі як OPC UA, для забезпечення синхронізації даних у реальному часі.

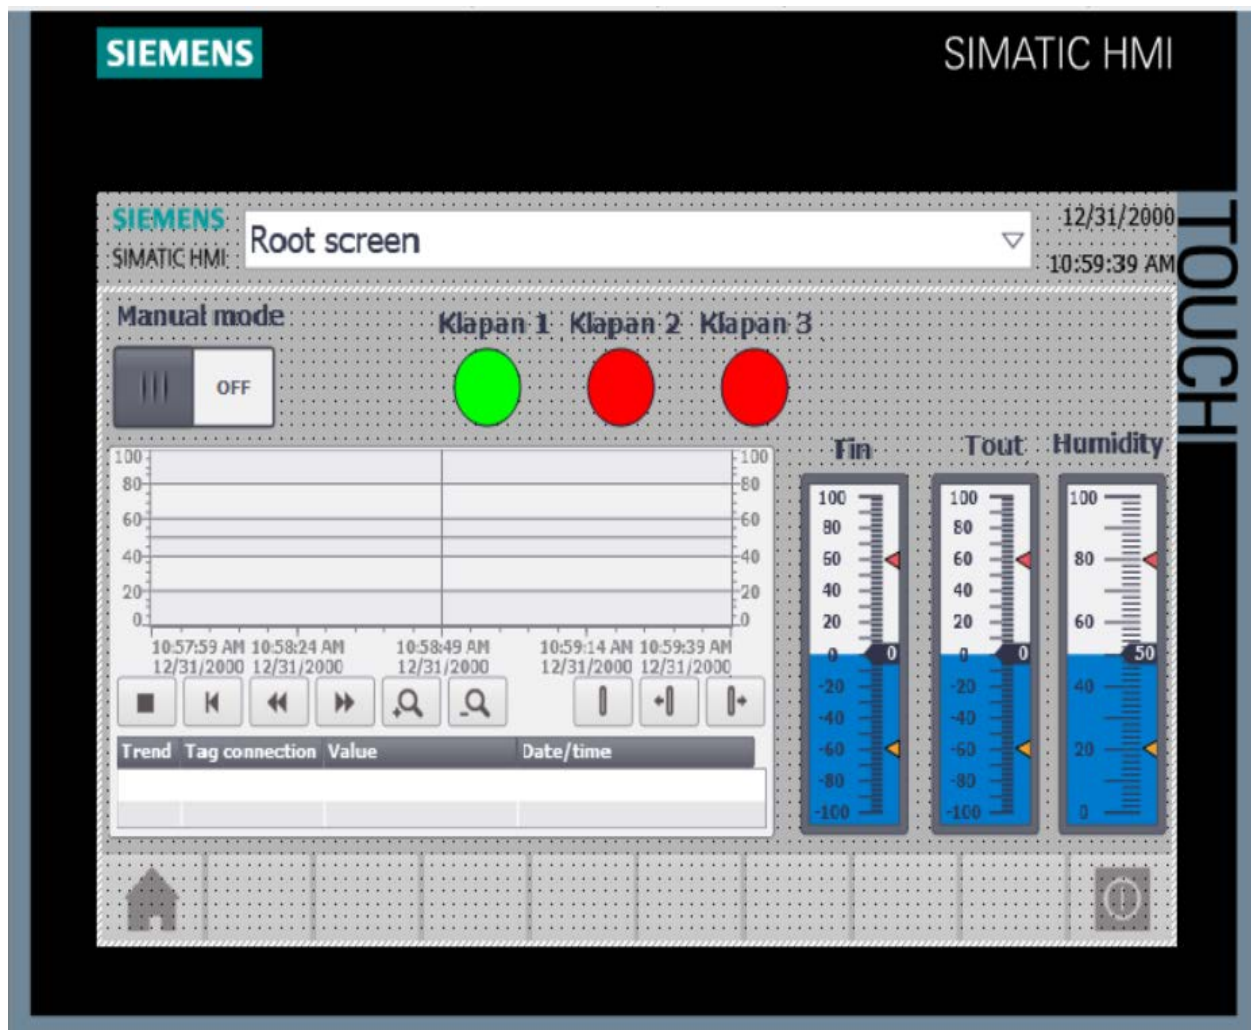


Рисунок 3.18 – Панель оператора

Висновки до розділу

У цьому розділі було виконано комплексну роботу, спрямовану на створення та інтеграцію системи керування на основі нейронної мережі для автоматизації процесу регулювання мікроклімату. Спочатку була зібрана база даних, яка включала 1000 прикладів із вхідними та вихідними параметрами, що відображають роботу клапанів системи. На основі цих даних було проведено навчання нейронної мережі, яка успішно виконала прогнозування вихідних параметрів із високою точністю.

Для подальшої роботи з навченою моделлю була створена схема в Simulink, що забезпечує взаємодію системи керування з зовнішніми об'єктами через протокол OPC UA. Це рішення дозволяє ефективно інтегрувати розроблену нейронну мережу в промислові системи автоматизації, забезпечуючи гнучкість і надійність передачі даних.

На завершальному етапі виконано інтеграцію системи керування в середовище TIA Portal, де була розроблена панель оператора для зручного контролю та управління процесами. Цей інтерфейс дозволяє операторам отримувати візуалізацію роботи системи в реальному часі, коригувати налаштування та відслідковувати ефективність її роботи.

Отже, результати роботи підтверджують, що розроблена система є ефективним рішенням для автоматизації та покращення контролю процесів регулювання мікроклімату. Використання сучасних технологій, таких як нейронні мережі, Simulink, OPC UA та TIA Portal, забезпечує інтегровану й адаптивну платформу для промислового застосування.

ВИСНОВКИ

У магістерській роботі було виконано комплексне дослідження, спрямоване на створення системи управління параметрами клімату в процесі зберігання борошна. Ця система базується на використанні штучної нейронної мережі. Проведені дослідження підтвердили доцільність і ефективність застосування сучасних інтелектуальних підходів до автоматизації технологічних процесів, де традиційні методи не здатні забезпечити належну якість управління.

На основі детального аналізу технологічного процесу зберігання борошна було виявлено, що температура, вологість повітря та рівень вуглекислого газу є критичними параметрами. Відхилення від оптимальних умов значно впливає на якість зберігання продукту. Через нелінійність взаємозв'язків між параметрами традиційні методи автоматизації виявляються недостатньо ефективними. Саме тому для управління було обрано підхід із використанням нейронних мереж, які здатні моделювати складні залежності та адаптуватися до змін умов.

Для навчання нейронної мережі було підготовлено навчальну вибірку, що складається з 1000 прикладів. Вхідними даними для моделі є температури повітря всередині та зовні приміщення, вологість, а також рівні вуглекислого газу. На виході нейронна мережа прогнозує відсотки відкриття клапанів, які регулюють подачу тепла, пари та свіжого повітря. Використання методів навчання з учителем і алгоритму градієнтного спуску дозволило досягти високої точності прогнозування.

На базі розробленої моделі було створено систему моделювання в MATLAB/Simulink. Для забезпечення інтеграції з промисловими пристроями передбачено використання протоколу OPC UA. Це дозволяє використовувати систему в реальному технологічному середовищі, забезпечуючи гнучкість і масштабованість.

Подальша інтеграція розробленої системи в середовище TIA Portal дозволила створити панель оператора для зручного управління процесом. Інтерфейс панелі забезпечує можливість моніторингу параметрів і зміни налаштувань як в автоматичному, так і в ручному режимах. Це забезпечує простоту експлуатації та гнучкість системи.

Експериментальні дослідження продемонстрували високу відповідність між фактичними та прогнозованими значеннями. Нейронна мережа показала здатність точно моделювати поведінку системи, адаптуватися до змін умов зберігання та забезпечувати ефективне управління.

Розроблена система є значущою не лише для автоматизації процесів зберігання борошна, але й має потенціал для використання в інших галузях, де важливе точне регулювання параметрів мікроклімату. Результати роботи підтверджують, що нейронні мережі є ефективним інструментом для розв'язання складних завдань автоматизації, зокрема у харчовій промисловості.

СПИСОК ВИКОРИСТАНОЇ ЛІТЕРАТУРИ

- 1.Іванченко, М. Г., та Ковальчук, О. В. Математичне моделювання у задачах автоматизації технологічних процесів. Київ: Наукова думка, 2020. 320 с.
- 2.Петренко, А. П., та Гусак, Л. В. Основи теорії автоматичного управління. Харків: Видавництво Харківського національного університету, 2019. 280 с.
- 3.Goodfellow, I., Bengio, Y., & Courville, A. Deep Learning. Cambridge, MA: MIT Press, 2016. 775 p.
- 4.Haykin, S. Neural Networks and Learning Machines. 3rd ed. Upper Saddle River, NJ: Pearson Education, 2009. 906 p.
- 5.Chollet, F. Deep Learning with Python. Shelter Island, NY: Manning Publications, 2018. 384 p.
- 6.Верба, С. П., та Калініченко, С. А. Системи управління процесами зберігання зерна. Полтава: Аграрний університет, 2021. 240 с.
- 7.Bishop, C. M. Pattern Recognition and Machine Learning. New York: Springer, 2006. 738 p.
- 8.Smola, A. J., & Schölkopf, B. A Tutorial on Support Vector Regression. Statistics and Computing, 2004. 14(3): 199–222.
- 9.Szegedy, C., Liu, W., Jia, Y., et al. Going Deeper with Convolutions. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2015, pp. 1–9.
- 10.Кравець, В. І., та Шевчук, М. О. Адаптивні системи керування: моделі та алгоритми. Львів: Видавництво Львівського політехнічного інституту, 2022. 310 с.
- 11.Hornik, K., Stinchcombe, M., & White, H. Multilayer Feedforward Networks are Universal Approximators. Neural Networks, 1989. 2(5): 359–366.
- 12.LeCun, Y., Bengio, Y., & Hinton, G. Deep Learning. Nature, 2015. 521(7553): 436–444.

- 13.Іванов, О. С., та Василенко, А. П. Методи автоматизованого керування у виробничих системах. Київ: Техніка, 2018. 292 с.
- 14.Козлов, В. М., та Мельник, Т. Ю. Сучасні системи автоматизації технологічних процесів. Вінниця: Університетське видавництво, 2020. 320 с.
- 15.Glorot, X., & Bengio, Y. Understanding the Difficulty of Training Deep Feedforward Neural Networks. Proceedings of the International Conference on Artificial Intelligence and Statistics (AISTATS), 2010, pp. 249–256.
- 16.Kingma, D. P., & Ba, J. Adam: A Method for Stochastic Optimization. arXiv preprint arXiv:1412.6980, 2014.
- 17.Жуковський, Д. В., та Приймак, О. В. Прогнозування процесів в агропромислових системах. Одеса: Наука і техніка, 2021. 256 с.
- 18.Krizhevsky, A., Sutskever, I., & Hinton, G. E. ImageNet Classification with Deep Convolutional Neural Networks. Communications of the ACM, 2017. 60(6): 84–90.
- 19.Сидоренко, Л. В., та Колесник, В. О. Інтелектуальні технології в управлінні промисловими процесами. Дніпро: Національний технічний університет, 2021. 300 с.
- 20.Szegedy, C., Vanhoucke, V., Ioffe, S., et al. Rethinking the Inception Architecture for Computer Vision. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016, pp. 2818–2826.
- 21.Brownlee, J. Master Machine Learning Algorithms. Melbourne, Australia: Machine Learning Mastery, 2016. 235 p.
- 22.Гуменюк, П. І., та Бойко, В. С. Автоматизація зберігання харчової сировини. Харків: Видавництво Національного університету, 2019. – 230 с.
- 23.Rumelhart, D. E., Hinton, G. E., & Williams, R. J. Learning Representations by Back-Propagating Errors. Nature, 1986. 323(6088): 533–536.
- 24.Zadeh, L. A. Fuzzy Sets. Information and Control, 1965. 8(3): 338–353.
- 25.Ільченко, А. М., та Степаненко, Ю. С. Моделі та методи прогнозування у задачах автоматизації. Чернівці: Видавництво Чернівецького університету, 2022. 310 с.

26.Schmidhuber, J. Deep Learning in Neural Networks: An Overview. *Neural Networks*, 2015. 61: 85–117.

27.Кравчук, І. С., та Савчук, М. О. Системи керування складними об'єктами. Рівне: Технічний університет, 2019. 275 с.

28.Silver, D., Huang, A., Maddison, C. J., et al. Mastering the Game of Go with Deep Neural Networks and Tree Search. *Nature*, 2016. 529(7587): 484–489.

29.Іванюк, Т. В., та Скорик, В. Л. Інтелектуальні системи підтримки прийняття рішень. Запоріжжя: Вид-во ЗНТУ, 2021. 245 с.

30.Abadi, M., Barham, P., Chen, J., et al. TensorFlow: A System for Large-Scale Machine Learning. *Proceedings of the 12th USENIX Symposium on Operating Systems Design and Implementation (OSDI)*, 2016, pp. 265–283.