

Карпенко Р.В.

Національний університет харчових технологій

ПРОГНОЗУВАННЯ ІНТЕНСИВНОСТІ УТВОРЕННЯ ВІДКЛАДЕНЬ НА ПОВЕРХНЯХ НАГРІВУ ТВЕРДОПАЛИВНОГО ЕНЕРГЕТИЧНОГО КОТЛА З ВИКОРИСТАННЯМ МОДЕЛІ НЕЙРОННИХ МЕРЕЖ

Твердопаливні енергетичні котли є важливим елементом у системах енергетичного забезпечення. Проте, з часом на поверхнях нагріву утворюються відкладення, які негативно впливають на їх ефективність. З'ясовано, що ці відкладення утворюються при температурі газів на виході з топки, більш високій, ніж температура розм'якшення золи, а при підвищенні температури зовнішній шар шлаку оплавляється, що сприяє налипанню нових часток і прогресуючому шлакуванню.

В даній статті досліджено використання нейронної мережі NARX для прогнозу температури в кожній із зон топки, що дає змогу оцінити майбутню ступінь забруднення поверхонь нагріву, так як існує відповідна закономірність. Завдяки своїй здатності до навчання на великих обсягах даних, NARX мережа добре підходить для вирішення даної задачі.

Попередні дослідження показали, що впровадження нейронних мереж у процес моніторингу та очищення поверхонь нагріву допомагає збільшити точність при збільшенні кількості прихованих нейронів мережі. При цьому виключається людський фактор та недолік недостатньої точності традиційних методів вимірювання і реагування. Потенційно це дозволяє зменшити витрати на енергетичні ресурси, а також знизити викиди забруднюючих речовин та надлишкового тепла в атмосферу.

В даній статті розкрито застосування моделі прогнозу температури в конкретній зоні топки, базуючись на даних по температурі в зоні, швидкості руху колосникової решітки, кількості палива і кількості повітря в кожну зону топки. Прогноз дозволяє автоматично корегувати кількість повітря в цільовій зоні топки для досягнення оптимальної якості згоряння. За рахунок цього досягається мінімізація кількості незгорілих частинок, що можуть осаджуватись на конвективних поверхнях теплообміну котла.

В результаті порівняння показників метрик передбачень нейронної мережі NARX з “closed-loop” архітектурою прослідковується тенденція на збільшення точності передбачення при збільшенні кількості прихованих нейронів мережі.

Ключові слова: твердопаливний котел; автоматизація; моніторинг; нейронні мережі; прогнозування; очищення поверхонь нагріву.

Постановка проблеми. У даній статті розглянуто проблему накопичення відкладень та очищення поверхонь нагріву твердопаливного енергетичного котла.

У процесі роботи котла виникає забруднення зовнішніх поверхонь нагрівання. На поверхнях нагріву відкладається шлак та незгорівші частинки твердого палива. Ці відкладення утворюються при температурі газів на виході з топки, більш високій, ніж температура розм'якшення золи, а також у високотемпературних зонах топки при незадовільній аеродинамічній організації топкового процесу в тих випадках, коли розплавлені частки золи, які не встигають остудитися і затвердіти, накидаються потоком газів на стінки топок і труби екранів. Звичайне шлакування

починається в проміжках між екранними трубами, а також у застійних зонах і ділянках топки. Якщо температура топкового середовища в зоні утворення шлакових відкладень нижча температури початку деформації золи, то зовнішній шар шлаку складається із затверділих часток. При підвищенні температури зовнішній шар шлаку може оплавлятися, що сприяє налипанню нових часток і прогресуючому шлакуванню.

Шлакування зменшує теплосприйняття поверхонь нагрівання, розташованих у топці, і підвищує температуру продуктів згоряння на виході з топки, що може призвести до порушення нормального гідродинамічного режиму роботи екранів котла. В області пароперегрівника, якщо температура газів низька, мають місце ущільнені

відкладення твердих часток золи. В економайзері утворюються пухкі сипучі відкладення дрібних фракцій золи, причому ріст забруднюючого шару супроводжується руйнуванням його більш великими частками, у результаті чого встановлюються динамічна рівновага і сталий стан забруднюючого шару. По досягненні визначеної товщини забруднення, зола більше не осаджується на забруднених трубах.

Внаслідок забруднення конвективних поверхонь нагрівання погіршуються умови теплопередачі і підвищуються їхні аеродинамічні опори. В результаті, підвищується температура відхідних газів, збільшуються втрати палива і витрата електроенергії на тягу [1, с. 58].

Відкладення на поверхнях нагріву призводять до зниження теплової ефективності котлів, що, в свою чергу, збільшує витрати пального та викиди забруднюючих речовин в навколишнє середовище. Традиційні методи моніторингу, такі як візуальний огляд та періодичні вимірювання, не завжди забезпечують своєчасне виявлення проблем. Це підкреслює необхідність впровадження нових технологій, які б дозволили автоматизувати процеси моніторингу та очищення.

Тож, при спалюванні твердих видів палива (вугілля, пелета лушпиння соняшника, гранульований жом, тріска деревини, тощо), поряд з наявністю та відносною дешевизною сировини, виникає ряд проблем:

1) Підвищена температура вихідних газів перед рукавними фільтрами, що призначені для їх очистки, досягає 190-200°C, що не дозволяє їх експлуатувати, адже при такій температурі починається руйнування рукавів. При цьому, в навколишнє середовище потрапляє більше забруднюючих речовин з температурою, що перевищує всі норми;

2) Зменшення К.К.Д котла за рахунок зменшення коефіцієнта теплопередачі від димових газів до води та пари (водотрубного контуру). Це збільшує витрати на енергоносії;

3) Підвищення ризику виходу з ладу екранів – трубної системи поверхонь нагріву, внаслідок перегрівання ділянок труб з надмірним засміченням золою. Це може призвести до аварійних ситуацій та додаткових затрат внаслідок простою обладнання.

Аналіз останніх досліджень і публікацій.

Для забезпечення ефективної оптимізації процесу видалення сажі необхідне отримання даних у режимі реального часу. Серед прямих методів моніторингу процесів шлакування переважають підходи, засновані на контролі температури димових газів та теплового потоку [3, с. 17; 4, с. 59]. Ряд дослідників ідентифікують температуру димових газів у котлі як ключовий індикатор для діагностики шлакування. Так, Білірген [5, с. 115] здійснив аналіз впливу паливного складу, експлуатаційних параметрів котла та особливостей системи видування сажі на процеси шлакоутворення шляхом моніторингу температури газів на виході з котла, а також розробив відповідні стратегії зниження інтенсивності шлакування. Чжан [6, с. 84; 7, с. 126] застосував інноваційну технологію акустичної пірометрії для контролю температури димових газів з метою кількісної оцінки ступеня шлакування.

З огляду на велику кількість факторів, що можуть впливати на температуру димових газів у твердопаливних котлах, такий показник може відображати зміни рівня забруднення лише за умов стабільного режиму роботи. У низці досліджень розглядалася можливість встановлення вимірювальних приладів на екранах котла з метою




Рис. 1. Графік залежності шлакування поверхонь нагріву від температури горіння палива

визначення теплового потоку як індикатора тенденції до шлакування. Зокрема, Теруель [8, с. 60] і Пена [9, с. 11] здійснили вимірювання теплового потоку за умов забруднених та чистих поверхонь теплообміну, застосовували відповідні сенсори, а на основі отриманих експериментальних даних побудували штучні нейронні мережі для прогнозування інтенсивності шлакоутворення. Проте, через складну та турбулентну динаміку середовища горіння в топковому просторі котла, монтаж вимірювальних пристроїв на екранах та забезпечення їх довготривалої надійної роботи становить значну технічну складність і потребує істотних фінансових витрат.

Окрім методів прямого моніторингу, у ряді досліджень було запропоновано підходи до непрямого контролю шлакування, засновані на енергетичному балансі. Зокрема, Талер [10, с. 30] розробив систему моніторингу, яка базується на енергетичному балансі та забезпечує кількісну оцінку ступеня забруднення топкових і конвективних теплообмінних поверхонь. Ромео [11, с. 19; 12, с. 26] реалізував систему моніторингу, що поєднує метод енергетичного балансу зі штучними нейронними мережами та методами нечіткої логіки з метою оптимізації процесу очищення поверхонь нагріву котла. У згаданих дослідженнях [10-12] в якості контрольної змінної використовувалося співвідношення між фактичними змінними стану, такими як поглинене тепло або коефіцієнт теплопередачі, та відповідними значеннями для умов теоретично чистого стану.

У зазначених дослідженнях параметри теоретично чистого стану визначалися на основі проєктних або емпіричних значень, при цьому не враховувався вплив непрацюючих та змінних експлуатаційних умов. Крім того, у ряді робіт [9, 10] було реалізовано підхід, за яким критичний індикатор визначався на основі моделі оптимізації, а подальша оцінка необхідності проведення продування сажі здійснювалася шляхом порівняння фактичних значень змінних моніторингу з наперед встановленим критичним порогом. Варто підкреслити, що точність визначення моменту сажообдуду повністю залежала від достовірності даних моніторингу. Враховуючи неминучі коливання результатів вимірювань в умовах змінного технологічного режиму котла, розрахований оптимальний момент очищення теплообмінних поверхонь міг бути недостатньо надійним.

Проведений огляд літературних джерел свідчить про актуальність подальших досліджень у сфері моніторингу шлакування та оптимізації

процесу сажообдудування. Це особливо важливо з огляду на обмежене поширення та недостатню ефективність існуючих рішень у практичному застосуванні для котлів відповідного типу палива та способу спалювання.

Метою цієї роботи є створення системи моніторингу забруднення поверхонь нагріву твердопаливних котлів, що базується на моделі прогнозування відкладень сажі. Модель прогнозує температуру в конкретній зоні топки, базуючись на поточній температурі в зоні, кількості палива і кількості повітря у зону. Ці дані дають змогу оцінити якість згорання палива. Ця оцінка дозволяє корегувати кількість повітря в цільовій зоні топки для досягнення оптимальної якості горіння. За рахунок цього досягається мінімізація кількості незгорілих частинок палива, що можуть осаджуватись на конвективних поверхнях теплообміну котла.

Виклад основного матеріалу. Твердопаливний котел під час роботи накопичує на поверхнях нагріву сажу та незгорілі тверді частинки палива, що погіршує теплопередачу, збільшує витрати пального та викиди забруднюючих речовин в навколишнє середовище, а з часом може призвести і до пошкодження трубної системи.

В якості показників, по яким можна визначити якість згорання палива, виступають наступні змінні:

Таблиця 1

Змінні, що визначають якість горіння в зоні

Змінна	Метод вимірювання або розрахунку
Температура в зоні горіння	Вимірюється оптичним спектроаналізатором
Витрата повітря в зону горіння	Вимірюється трубкою Піто методом перепаду тисків
Витрата палива в зону горіння	Розраховується по швидкості руху колосникової решітки та висоті шару палива.

Система спектрального моніторингу температури в топці працює наступним чином (Рис. 2).

Площина топки котла розділяється на кілька областей, кожна з яких моніторить сенсор. Конструктивно, кожна зона, по загальному периметру топки, містить в собі частину екранних труб, що розміщені на стінах топки. В якості сенсорів для спектрального моніторингу використовуються оптичні спектрометри, але можуть бути застосовані також ІЧ-камери (тепловізори), фотодетектори та лазерні газоаналізатори.

В процесі роботи, система отримує дані зі значеннями температури, кількістю повітря, кіль-

кістю палива та його розподілом на колосниковій решітці в кожній із зон горіння. Для якісного спалювання палива з мінімальною кількістю шлаку та незгорілих часток, існує закономірність, а саме, так зване «співвідношення між кількістю палива та кількістю повітря» в зоні горіння, яке необхідне для спалення цього палива. Якщо ж дане співвідношення не витримується (часто це буває внаслідок різкої зміни фракції палива чи механічних затримок під час просипання з бункера на колосникову решітку) – відбувається або його

неповне згорання, або так званий «провал», при якому відбувається прискорене згорання з подальшим небажаним розхолодженням топки.

На рисунку 3 зображено структурну схему даної системи, де центральним елементом в якості моделі якості виступає нейронна мережа:

Для прогнозування температури в зоні горіння, математично модель буде виглядати наступним чином:

$$y(k) = f(y(k-1), y(k-2), y(k-3), \dots, y(k-n), x(k), x(k-1), x(k-2), \dots, x(k-m)) + \varepsilon_k \quad (1)$$



Рис. 2. Схематичне зображення топки, що поділена на зони (вид зверху, на рухому колосникову решітку)




Рис.. 3. Структурна схема системи

де y – змінна «Прогнозована температура в зоні горіння», а x – вектор вхідних змінних;

m та n – це відповідно вхідна та вихідна затримки;

ε_k – член похибки;

функція f є нелінійною функцією, яка моделюється як штучна нейронна мережа прямого поширення.

Для моделі прогнозування температури в зоні горіння твердопаливного котла приймаємо змінні наступним чином:

Таблиця 2

Змінні моделі прогнозування температури в зоні горіння твердопаливного котла

Змінна	Параметр
y	Прогнозована температура в зоні горіння
$x(1)$	Поточна температура в зоні горіння
$x(2)$	Кількість палива для горіння
$x(3)$	Кількість повітря для горіння

Процес горіння твердого палива є доволі складним, нестационарним та нелінійним, тому моделювання цього промислового процесу на основі теорії термодинаміки є задачею вкрай складною. Однак, завдяки використанню нейронної мережі NARX, цю задачу можна значно спростити.

Для вирішення проблематики, порушеної даною темою, пропонується застосувати саме модель нейронної мережі NARX (нелінійна авто-регресивна екзогенна нейронна мережа). Вперше NARX була запропонована І. Дж. Леонтарітісом та С. А. Біллінгсом у 1985 році [2, с. 303].

Архітектури NARX моделей можуть бути як замкнені (closed-loop) так і розімкнені (open-loop). Розглянемо замкнену архітектуру NARX мережі на прикладі нашої задачі прогнозування, так як розімкнена показує наскільки добре мережа вміє відтворювати дані, якщо їй підказувати правильні виходи, а замкнена показує, як модель поводитиметься у реальному прогнозуванні, коли таких підказок немає. Хоча в замкнених архітектурах похибка з часом накопичується, вона показує справжню поведінку на горизонті прогнозу, а отже, дослідження та застосування замкнених архітектур має більшу наукову та практичну цінність.

Навчання нейронної мережі передбачає використання історичних даних про процес горіння, від якості якого залежить кількість відкладень на трубах в майбутньому. Це дозволить моделі навчитися розпізнавати критичні стани та своєчасно реагувати на них. Нейронні мережі також здатні виявляти закономірності, які можуть свідчити про нерівномірність процесу згорання палива на решітці.

Процес моделювання нейронної мережі включає в себе такі кроки:

Крок 1: У процесі збору даних, історичні дані збираються системою моніторингу з дискретністю 5 хв.

Крок 2: Процес попередньої обробки даних. Дані, зібрані на кроці 1, згладжуються та фільтруються. При цьому, неповні дані видаляються, а дані під час стабільної роботи зберігаються. Після виключення недостовірних даних, дані перевіряються на наявність ознак, і типи даних із сильною кореляцією з контрольною ціллю залишаються.

Крок 3: Побудова моделі нейронної мережі. Вищезгадані вхідні та вихідні дані використовуються як навчальні вибірки для побудови моделі нейронної мережі; за допомогою навчальної вибірки (70% датасету) ваги нейронів у моделі нейронної мережі будуть постійно оновлюватися та ітеруватися, доки не буде отримана нейронна мережа з меншою похибкою.

Крок 4: Після отримання навченої моделі нейронної мережі необхідно виконати перехресну перевірку валідаційними даними (15% датасету) для перевірки точності моделі.

Крок 5: Після перевірки валідаційними даними проводиться перевірка тестовими даними (останні 15% датасету) для перевірки якості прогнозування моделі. Вкінці як за остаточну модель прогнозування вибирається нейронна мережа з найвищою точністю та без переналаштування.

У реальному промисловому процесі модель нейронної мережі прогнозує вихідні дані, такі як розподіл температури в топці котла. Ці прогнозовані значення відіграють ключову роль у наступних кроках. Окрім прогнозування температури, за допомогою цієї ж моделі також можна передбачити значення викидів NOx та температуру газів [5, с. 115].

Мережа NARX використовується для прогнозування зміни температури на 4 кроки вперед. Виходи першого прогнозу $T(k+1)$, використовуються як вхідні дані для наступного прогнозу $T(k+2)$ і так далі. Після цього результат прогнозу передається до процедури ковзної оптимізації, яка створює поточні та майбутні сигнали керування. Використовується замкнена (closed-loop) архітектура NARX-моделі, що дає змогу враховувати дані на попередніх ітераціях прогнозу.

Дослідження проводились в програмному середовищі MATLAB R2025a. Було проведено навчання множини моделей на реальних даних, але з різною кількістю прихованих нейронів




Рис. 4. Структура нейронної мережі NARX




Рис. 5. Реальні та прогнозовані значення температури в зоні топки при використанні 20 прихованих нейронів мережі




Рис. 6. Реальні та прогнозовані значення температури в зоні топки при використанні 40 прихованих нейронів мережі

мережі. Базові налаштування: затримка 1:30. Дискретність даних – 5 хв., Прогнозування на 4 кроки вперед.

Для порівняння результатів передбачення математичних моделей було використано наступні показники:

1. **MSE** (Mean Squared Error) – метрика, яка використовується для оцінки якості прогнозу моделі, особливо в задачах регресії. MSE показує середнє значення квадратів помилок між фактичними значеннями (y_i) і прогнозованими значеннями ($\hat{y}_i$):

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (2)$$

де n – кількість спостережень, y_i – фактичне (реальне) значення, $\hat{y}_i$ – прогнозоване значення, $(y_i - \hat{y}_i)^2$ – квадрат помилки для кожного спостереження;

2. **R²** (коефіцієнт детермінації) – статистична метрика, яка показує, наскільки добре модель пояснює варіацію цільової змінної у порівнянні з її середнім значенням:

$$R^2 = 1 - \frac{RSS}{TSS} \quad (3)$$

де: $RSS = \sum (y_i - \hat{y}_i)^2$ – залишкова сума квадратів (помилки моделі), $TSS = \sum (y_i - \bar{y})^2$ – загальна сума квадратів (варіація фактичних значень навколо середнього), y_i – фактичне значення, $\hat{y}_i$ – прогнозоване значення, $\bar{y}$ – середнє значення фактичних значень.

3. **MAE** (Mean Absolute Error, середня абсолютна похибка) – це метрика, яка показує,

наскільки в середньому модель помиляється, незалежно від напрямку помилки (перевищення або недооцінка).

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i^{\text{реальне}} - \hat{y}_i^{\text{прогноз}}| \quad (4)$$

де:

- $y_i^{\text{реальне}}$ – справжнє значення
- $\hat{y}_i^{\text{прогноз}}$ – значення, передбачене моделлю
- n – кількість точок

В результаті порівняння показників метрик передбачень нейронної мережі NARX з Closed-loop архітектурою, можемо зазначити, що про-

Таблиця 3

Результати передбачення на навчальних даних (70% датасету)

Налаштування мережі	R ²	MSE	MAE
20 прихованих нейронів, затримка 1:30	0.406	2079.9	36.382
40 прихованих нейронів, затримка 1:30	0.635	1277.370	28.282
80 прихованих нейронів, затримка 1:30	0.948	537.585	17.987

Таблиця 4

Результати передбачення на валідаційних даних (15% датасету)

Налаштування мережі	R ²	MSE	MAE
20 прихованих нейронів, затримка 1:30	0.411	2052.9	35.954
40 прихованих нейронів, затримка 1:30	0.644	1257.8	27.867
80 прихованих нейронів, затримка 1:30	0.947	539.7	18.067




Рис. 7. Реальні та прогнозовані значення температури в зоні топки при використанні 80 прихованих нейронів мережі




Рис. 8. Порівняння якості прогнозування під час тренування, валідації та тестуванні мережі




Рис. 9. Показники регресії під час тренування, валідації та тестуванні моделі мережі




Рис. 10. Порівняння значень похибок при різній кількості прихованих нейронів

Таблиця 5
Результати передбачення на тестових даних
(15% датасету)

Налаштування мережі	R ²	MSE	MAE
20 прихованих нейронів, затримка 1:30	0,416	2082.9	36.145
40 прихованих нейронів, затримка 1:30	0,651	1233.6	27.176
80 прихованих нейронів, затримка 1:30	0.939	534.4	17.266

слідковується тенденція на покращення показників метрик зі збільшенням кількості прихованих нейронів:

- **R²**: виріс більш ніж удвічі.
- **MSE**: зменшився майже в 4 рази.
- **MAE**: зменшився удвічі.

На рисунку 10 зображено гістограму порівняння значень похибок при різній кількості прихованих нейронів:

Отже, по результатам досліджень, в якості налаштувань NARX мережі обрано варіант «80 прихованих нейронів, затримка 1:30», так як з такими налаштуваннями похибка прогнозу найменша:

$$\text{MSE} = 537.585;$$

$$\text{MAE} = 17.987.$$

При цьому регресія $R^2 = 0.948$, що вказує на те, що модель дуже добре відображає зв'язок між вхідними даними та цільовими значеннями.

Висновки. Попередні дослідження показали, що впровадження нейронних мереж у процес моніторингу та очищення поверхонь нагріву допоможе збільшити точність при значній кількості прихованих нейронів мережі. При цьому виключається людський фактор та недолік недостатньої точності традиційних методів вимірювання і реагування. Потенційно це зменшить витрати на енергетичні ресурси, а також знизить викиди забруднюючих речовин в атмосферу.

Оптимізація моніторингу процесу горіння та очищення поверхонь нагріву твердопаливного енергетичного котла з використанням нейронних мереж є перспективним напрямком, що дозволяє підвищити ефективність роботи котлів та зменшити їх негативний вплив на навколишнє середовище. Подальші дослідження в цій галузі можуть призвести до значних покращень у сфері енергетики.

Також для подальших досліджень можливо використати необроблені спектральні дані з сенсорів спектрометрів, що покращить визначення можливої нерівномірності згорання палива на решітці твердопаливного котла.

Список літератури:

1. Карпенко Р.В. Интеллектуальная подсистема поддержки принятия решений щодо оптимізації очищення поверхонь нагріву твердопаливного енергетичного котла. Київ: НУХТ. Харчова промисловість. 2023. 58 с.
2. Leontaritis I.J., Billings S.A. Input-output parametric models for non-linear systems. Part I: deterministic non-linear systems. *Int'l J of Control*. 2020. 303-328 с.
3. Pattanayak L., Ayyagari S.P.K., Sahu J.N. Optimization of sootblowing frequency to improve boiler performance and reduce combustion pollution. *Clean Technol. Environ. Policy* 2015. 17 с.

4. Diaz-Bejarano E., Coletti F., Macchietto S. A model-based method for visual ization, monitoring, and diagnosis of fouling in heat exchangers. *Ind. Eng. Chem. Res.* 2020. 59 с.
5. Bilirgen H. Slagging in PC boilers and developing mitigation strategies. *Fuel*. 2014. 115 с.
6. Zhang S., Shen G., An L., Li G. Ash fouling monitoring based on acoustic py rometry in boiler furnaces, *Appl. Therm. Eng.* 2015. 84 с.
7. Zhang S., Shen G., An L., Niu Y., Jiang G. Monitoring ash fouling in power station boiler furnaces using acoustic pyrometry, *Chem. Eng.* 2015. 126 с.
8. Teruel E., Cortes C., Ignacio Díez L., Arauzo I. Monitoring and prediction of fouling in coal-fired utility boilers using neural networks, *Chem.* 2005. 60 с.
9. Pena B., Teruel E., Díez L.I. Soft-computing models for soot-blowing optimi zation in coal-fired utility boilers, *Appl. Soft Comput.* 2011. 11 с.
10. Taler J., Taler D. Slag monitoring system for combustion chambers of steam boilers, *Heat Tran. Eng.* 2009. 30 с.
11. Romeo L.M., Gareta R. Hybrid System for fouling control in biomass boilers, *Eng. Appl. Artif. Intell.* 2006. 19 с.
12. Romeo L.M., Gareta R. Neural network for evaluating boiler behaviour, *Appl. Therm. Eng.* 2006. 26 с.

Karpenko R.V. PREDICTION OF THE INTENSITY OF DEPOSIT FORMATION ON THE HEATING SURFACES OF A SOLID FUEL POWER BOILER USING A NEURAL NETWORK MODEL

Solid fuel boilers are an important element in energy supply systems. However, over time, deposits form on the heating surfaces, which negatively affect their efficiency. It was found that these deposits are formed at a temperature of gases at the outlet of the furnace, higher than the ash softening temperature, and with increasing temperature, the outer layer of slag melts, which contributes to the adhesion of new particles and progressive slag formation.

This article investigates the use of the NARX neural network to predict the temperature in each of the furnace zones, which makes it possible to estimate the future degree of contamination of heating surfaces, since there is a corresponding pattern. Due to its ability to learn on large amounts of data, the NARX network is well suited to solving this problem.

Previous studies have shown that the introduction of neural networks into the process of monitoring and cleaning heating surfaces helps to increase accuracy with an increase in the number of hidden neurons in the network. This eliminates the human factor and the lack of accuracy of traditional measurement and response methods. This potentially allows you to reduce energy costs, as well as reduce emissions of pollutants and excess heat into the atmosphere.

This article describes the application of a temperature forecast model in a specific zone of the furnace, based on data on the temperature in the zone, the speed of the grate movement, the amount of fuel and the amount of air in each zone of the furnace. The forecast allows you to automatically adjust the amount of air in the target zone of the furnace to achieve optimal combustion quality. This minimizes the number of unburned particles that can settle on the convective heat exchange surfaces of the boiler.

As a result of comparing the indicators of the prediction metrics of the NARX neural network with the “closed-loop” architecture, a tendency is observed to increase the prediction accuracy with an increase in the number of hidden neurons in the network.

Key words: solid fuel boiler; automation; monitoring; neural networks; forecasting; cleaning of heating surfaces.

Дата надходження статті: 04.09.2025

Дата прийняття статті: 19.09.2025

Опубліковано: 16.12.2025