

А. Р. Ліщук<sup>1</sup>  
В. М. Дубовой<sup>1</sup>

## ПОРІВНЯЛЬНИЙ АНАЛІЗ МОДЕЛЕЙ КОРОТКОСТРОКОВОГО ПРОГНОЗУВАННЯ ТЕМПЕРАТУРИ ЗЕРНА У ЗЕРНОСХОВИЩАХ

<sup>1</sup>Вінницький національний технічний університет

Короткострокове прогнозування температури зерна є важливою складовою інтелектуального моніторингу зерносховищ, оскільки дає змогу своєчасно виявляти небезпечні температурні тенденції, оцінювати ризик локального самозігрівання зернової маси та підвищувати ефективність прийняття рішень щодо подальшого зберігання продукції. Температурний стан зерна формується під впливом власної теплової інерції зернової маси, зовнішніх метеорологічних умов, вологості, типу культури, глибини розташування датчиків та просторової неоднорідності температурного поля. У зв'язку з цим актуальним є дослідження моделей, здатних враховувати як часову динаміку процесу, так і нелінійні взаємозв'язки між технологічними, метеорологічними та просторовими параметрами.

У статті досліджено моделі множинної лінійної регресії, LSTM, Compact ANFIS та гібридні архітектури LSTM-ANFIS для короткострокового прогнозування температури зерна на горизонтах 1, 3 і 6 годин уперед. Дослідження виконано на багатосерійному часовому датасеті, що охоплює дві зернові культури, чотири засіки, 24 підвіски та 72 температурні датчики. Вхідні дані містили погодинні вимірювання температури зерна, зовнішні метеорологічні параметри, характеристики розташування датчиків та додаткові інженерні ознаки. У процесі попередньої обробки даних сформовано лагові, статистичні, циклічні, просторові та режимні ознаки, а також цільові змінні для кожного горизонту прогнозування. Для уникнення витоку інформації розділення даних на навчальну, валідаційну та тестову вибірки виконувалося за часовим принципом.

У результаті кореляційного аналізу встановлено, що найінформативнішими для прогнозування температури зерна є поточне значення температури зерна, її лагові значення, ковзні статистики, різниця між температурою повітря та температурою зерна, оцінка вологості зерна, тип культури, глибина розташування датчика та просторово-режимні характеристики. Показано, що ефективність моделей істотно залежить від горизонту прогнозування. Для горизонту 1 година найкращою виявилася модель множинної лінійної регресії, яка забезпечила  $MAE = 0,10266$ ,  $RMSE = 0,16233$  та  $R^2 = 0,99228$ . Для горизонту 3 години найвищу точність продемонструвала гібридна модель LSTMEncoder + Compact ANFIS з результатами  $MAE = 0,29073$ ,  $RMSE = 0,39682$  та  $R^2 = 0,95375$ . Для горизонту 6 годин найкращою стала модель LSTMEncoder + Compact ANFIS Residual + Regime Features, яка досягла  $MAE = 0,53045$ ,  $RMSE = 0,73544$  та  $R^2 = 0,84081$ .

Отримані результати підтверджують, що для короткострокового прогнозування температури зерна достатньо ефективними можуть бути табличні моделі з якісно сформованими лаговими, статистичними та інженерними ознаками. Водночас зі збільшенням горизонту прогнозування зростає доцільність використання гібридних архітектур, які поєднують здатність LSTM враховувати часову динаміку з можливістю Compact ANFIS виконувати нелінійне уточнення прогнозу на основі фізично змістовних і просторово-режимних характеристик. Практичне значення отриманих результатів полягає у можливості використання запропонованого підходу в системах моніторингу зерносховищ, раннього попередження про небезпечні температурні зміни та підтримки прийняття рішень щодо керування мікрокліматом зернової маси.

**Ключові слова:** прогнозування температури зерна; зерносховище; короткострокове прогнозування; множинна лінійна регресія; LSTM; ANFIS; гібридна модель; часові ряди.

### Вступ

Забезпечення безпечного зберігання зерна є важливою складовою продовольчої безпеки, а температура зернової маси належить до ключових параметрів, що визначають якість продукції, ризик

самозігрівання, розвиток мікробіологічних процесів і рівень технологічних втрат під час зберігання. Тому прогнозування температури зерна має важливе практичне значення для систем моніторингу, раннього попередження та підтримки прийняття рішень у зерносховищах [1], [2].

Початкові підходи до прогнозування температури зерна ґрунтувалися переважно на використанні статистичних, регресійних і класичних методів машинного навчання, у яких основна увага приділялася зв'язку між температурою зернової маси та зовнішніми метеорологічними чинниками [1], [2]. Такі підходи підтвердили, що температура повітря, погодні умови та часовий лаг між змінами зовнішнього середовища і реакцією зернової маси є важливими факторами для побудови прогнозних моделей [1], [2]. Водночас використання лише обмеженого набору зовнішніх змінних не завжди забезпечує достатню точність у випадку складних нелінійних процесів тепло- і вологообміну в зерновій масі [1], [2].

Подальший розвиток цього напряму пов'язаний із застосуванням методів глибокого навчання, здатних враховувати як часові, так і просторові залежності в даних. Для прогнозування точкової температури зернового насипу використано згорткові нейронні мережі, що дозволило ефективніше враховувати температурні закономірності в околі цільової точки [3]. Поєднання просторових ознак зернової маси, зовнішніх метеорологічних факторів, механізмів уваги, CNN і LSTM дало змогу підвищити точність прогнозування за рахунок одночасного врахування локальних, глобальних і часових залежностей [4], [5]. Надалі для зменшення обчислювальної складності та підвищення якості прогнозу запропоновано архітектури на основі broad learning network, одномірних згорток, багатоголової self-attention і трансформерних механізмів багатомасштабного злиття ознак [6], [7]. До того ж до прогнозування температури зерна залучалися інтерпретовані просторово-часові трансформерні моделі, які дозволяють одночасно враховувати історичні температури, метеорологічні параметри, вологість зерна, тип культури та характеристики зерносховища [8].

Разом з безпосереднім прогнозуванням температури зерна, інтелектуальні методи активно застосовуються і в суміжних задачах аналізу та керування процесами зберігання. Темпоральна кореляція температури зерна може бути використана для виявлення змін режимів зберігання та роботи з неповними даними [9]. Контурні карти температурного поля можуть слугувати інформативною основою для класифікації режимів інвентаризації зерна та допомоги в управлінні зерносховищем [10]. Нейронні мережі також є ефективними для інтелектуального керування процесами сушіння зерна, де прогнозування параметрів процесу використовується для коригування режимів роботи сушильного обладнання [11]. Це свідчить про загальну тенденцію до ширшого використання інтелектуальних моделей у задачах моніторингу, прогнозування, класифікації станів і керування технологічними процесами в зерновій галузі [9]—[11].

Окрему групу перспективних підходів становлять нейро-нечіткі системи, які поєднують здатність нейронних мереж до навчання з інтерпретованим поданням знань у вигляді нечітких правил [12]. Серед таких підходів особливе місце посідає Adaptive Neuro-Fuzzy Inference System, яка є ефективною для моделювання нелінійних залежностей, але водночас має обмеження, пов'язані зі зростанням обчислювальної складності та кількості правил зі збільшенням кількості входів [13]. Нейро-нечіткі предиктори загалом демонструють придатність до моделювання складних нелінійних динамічних процесів із часово-змінними параметрами [14]. Моделі типу Takagi–Sugeno–Kang забезпечують поєднання точності, прозорості та компактності правила-бази, що є важливим для побудови адаптивних систем прогнозування [15]. Додаткове поєднання нечітких і ймовірнісних механізмів у TSK-підходах дозволяє підвищити якість моделі та її інтерпретованість [16].

У літературі також розглядаються прикладні постановки задачі прогнозування параметрів зернової маси з використанням нейромережевих та програмно-апаратних засобів. Зокрема, для прогнозування температури зерна в силосі за даними IoT-систем досліджено застосування моделей LSTM, GRU та CNN [17]. Нейромережеві підходи також використовувалися для прогнозування параметрів зернової маси, що зберігається у бункерах елеваторів [18]. Окремо розглядалися архітектурні рішення програмно-апаратних комплексів контролю та прогнозування параметрів зернової маси в елеваторних бункерах [19]. Сукупність цих досліджень підтверджує актуальність поєднання моделей аналізу часових даних, ознак стану зернової маси та інтелектуальних засобів підтримки прийняття рішень у системах зберігання зерна [17]—[19].

Отже, сучасні підходи до прогнозування температури зерна розвиваються у двох взаємодоповнювальних напрямках. Перший напрям орієнтований на побудову високоточних глибоких просторово-часових моделей, здатних працювати з багатовимірними послідовностями та складними залежностями [3]—[8]. Другий напрям зосереджений на використанні нейро-нечітких систем, які

забезпечують опис нелінійних взаємозв'язків у інтерпретованій формі [12]—[16]. Водночас результати сучасних досліджень і власних експериментів свідчать, що ефективність конкретної моделі істотно залежить від горизонту прогнозування та складу вхідних ознак. У зв'язку з цим перспективним є використання не лише окремих моделей LSTM і ANFIS, а й гібридних архітектур LSTM-ANFIS, у яких LSTM виконує функцію часового енкодера або базового аналітика, а нечіткий модуль забезпечує нелінійне доопрацювання прогнозу з урахуванням фізично змістовних табличних і просторово-режимних ознак.

*Метою статті* є дослідження моделей короткострокового прогнозування температури зерна у зерносховищах на горизонтах 1, 3 і 6 годин уперед та порівняння точності множинної лінійної регресії, LSTM, Compact ANFIS і гібридних архітектур LSTM-ANFIS за метриками MAE, RMSE та  $R^2$ . Особливу увагу приділено визначенню умов, за яких табличні моделі є достатніми, а використання гібридних LSTM-ANFIS-підходів забезпечує перевагу для середнього та довшого горизонтів прогнозування.

## Матеріали та методи

### Постановка задачі

У роботі розглянуто задачу короткострокового прогнозування температури зерна в зерносховищах на основі багатосерійних часових рядів, сформованих за даними температурних датчиків у зерновій масі та зовнішніх метеорологічних параметрів. Кожний часовий ряд відповідає окремому датчику, розміщеному в конкретному засіку та на певному рівні глибини, що дає змогу враховувати як часову динаміку процесу, так і його просторову неоднорідність.

Об'єктом дослідження є зерносховище складського типу з чотирма засіками, у двох з яких зберігається пшениця, а у інших двох — кукурудза. Конструкція сховища має жерстяне накриття та жерстяні перегородки між засіками (рис. 1). Висота насипу зерна в кожному засіку становить близько 3 м.



Рис. 1. Приклад зерносховищ складського типу, подібного до об'єкта дослідження

Для моніторингу температурного стану зернової маси використовувалися підвіски з датчиками, розміщеними на різних рівнях глибини. У кожному засіку встановлено шість підвісок, а на кожній підвісці — по три датчики: верхнього, середнього та нижнього рівнів. Така організація вимірювальної системи дає змогу враховувати вертикальний розподіл температури в зерновій масі та локальні особливості температурного режиму в межах окремих засіків.




Рис. 2. Схематичне зображення зерносховища, розташування засіків, підвісок і температурних датчиків

Формально задача полягає у побудові моделі, яка на основі поточних і попередніх значень температури зерна, метеорологічних параметрів, часових, просторових, інженерних та режимних ознак прогнозує майбутнє значення температури зерна через заданий горизонт уперед. У дослідженні розглянуто три горизонти прогнозування: 1, 3 і 6 годин. Для кожного з них формувалася окрема цільова змінна, що відповідає температурі зерна через відповідну кількість часових кроків.

Вхідний простір моделей включав поточне значення температури зерна, її лагові значення, ковальні статистики, погодні параметри зовнішнього середовища, циклічні часові ознаки, глибину розташування датчика, тип культури, час після засипки зерна, оцінені показники вологості зерна, а для довшого горизонту прогнозування — також просторово-режимні ознаки, що характеризують температурний стан засіку та локальне положення датчика відносно сусідніх точок вимірювання.

Для розв'язання поставленої задачі досліджено кілька класів моделей: множинну лінійну регресію як baseline-підхід, модель Compact ANFIS, рекурентні моделі LSTM, а також гібридні архітектури LSTM-ANFIS. Порівняння моделей виконувалося окремо для кожного горизонту прогнозування за метриками MAE, RMSE та  $R^2$ . Така постановка дозволяє визначити, як змінюється доцільність використання табличних, рекурентних, нейро-нечітких і гібридних моделей залежно від горизонту прогнозування температури зерна.

### Опис датасету

Для дослідження сформовано багатосерійний часовий датасет. Він містить погодинні вимірювання температури зерна та зовнішніх метеорологічних параметрів за період з березня по травень 2020 року. Початковий набір даних включав 107064 записи без пропусків і дублікатів та характеризувався сталою часовою дискретністю 1 година.

Структурно датасет охоплює дві зернові культури, чотири засіки, 24 підвіски та 72 окремі датчики, тобто 72 часові ряди температури зерна. Кожний ряд ідентифікується комбінацією ознак, що описують тип культури, номер засіку, номер підвіски та положення датчика за глибиною. Така структура дозволяє розглядати досліджуваний набір як панельний часовий ряд, у якому поєднуються локальна динаміка температури зерна, просторові особливості об'єкта та вплив зовнішнього середовища.

До складу вхідних даних увійшли кілька груп ознак. Перша група охоплює поточні значення температури зерна. Друга містить метеорологічні параметри зовнішнього середовища, зокрема температуру повітря, точку роси, відносну вологість, опади, швидкість і напрям вітру, атмосферний тиск, хмарність, видимість, сонячну радіацію, сонячну енергію та ультрафіолетовий індекс. Третя група включає часові, лагові та статистичні ознаки, сформовані на основі попередніх значень температури зерна. Четверта група представлена геометричними та просторовими характеристиками, зокрема глибиною розташування датчика, номером підвіски, номером засіку та кодом культури. Додатково до датасету включено інженерні ознаки, зокрема різницю між температурою повітря та температурою зерна, а також оцінено показники вологості зерна.

Для побудови моделей прогнозування у датасеті сформовано цільові змінні, що відповідають температурі зерна через 1, 3 і 6 годин уперед. До того ж, для довшого горизонту прогнозування до набору ознак додано просторово-режимні характеристики, які описують стан окремого засіку та локальне положення датчика відносно сусідніх вимірювальних точок. До таких ознак належать середня температура в засіку, стандартне відхилення температури в засіку, локальне відхилення температури датчика від середнього значення в засіку, середня температура по підвісці, локальне відхилення від середнього по підвісці, вертикальний температурний градієнт, а також похідні характеристики зміни температурного режиму в часі. Включення цих ознак дало змогу краще описати просторово-часову структуру процесу, особливо для прогнозування на 6 годин уперед.

Після структурної перевірки встановлено, що датасет є збалансованим за кількістю рядів і часових відліків: кожен із 72 датчиків має однакову довжину часового ряду. Така організація даних створює основу для коректного порівняння табличних, рекурентних, нейро-нечітких і гібридних моделей у єдиній експериментальній постановці.

### Теоретичне обґрунтування вибору вхідних змінних для прогнозування температури зерна

Формування температури зернової маси під час зберігання є наслідком пов'язаних процесів тепло- і масообміну між зерном та міжзерновим повітрям. У межах контрольного об'єму зміну температури зерна доцільно описувати через рівняння ентальпійного балансу зернової фази [20]

$$\frac{\partial(M_g T_g c_g)}{\partial t} = h_{sup} a V (T_a | T_g) - R_w M_g [h_{vap} | c_v (T_a | T_g)], \quad (1)$$

де  $T_g$  — температура зерна;  $T_a$  — температура повітря;  $M_g$  — маса зерна в контрольному об'ємі;  $c_g$  — питома теплоємність зерна;  $h_{sup}$  — коефіцієнт конвективного теплообміну між зерном і повітрям;  $a$  — питома площа контакту фаз;  $V$  — об'єм контрольного елемента;  $R_w$  — швидкість зміни вологості зерна;  $h_{vap}$  — питома теплота випаровування вологи із зерна;  $c_v$  — питома теплоємність водяної пари. Рівняння (1) безпосередньо показує, що швидкість зміни температури зерна визначається поточним температурним станом самого зерна, температурою повітря та інтенсивністю вологопереносу.

Важливо, що теплоємність зернової маси не є сталою, а залежить від її вологості. Для зернової фази використовується залежність [20]

$$c_g = c_s + W c_{wg}, \quad (2)$$

де  $c_s$  — питома теплоємність сухої речовини зерна;  $W$  — вологість зерна,  $c_{wg}$  — питома теплоємність води в зерні.

Отже, вологість зерна впливає на температурну динаміку двома шляхами: через зміну теплофізичних властивостей зернової маси та через участь у процесах випаровування і сорбції. Це обґрунтовує використання вимірної або оціненої вологості зерна серед вхідних ознак моделі прогнозування [20].

Динаміка вологості зерна в контрольному об'ємі описується рівнянням масового балансу [20]

$$\frac{\partial W}{\partial t} = -R_w. \quad (3)$$

Отже, температура зерна і його вологість є взаємопов'язаними змінними стану, а час після засипки природно входить у модель як незалежна змінна  $t$ . У практичній реалізації як ознаку доцільно використовувати не абсолютний час, а час після засипки  $\tau = t - t_{fill}$ , оскільки саме він відображає стадію розвитку теплових і вологісних процесів у насипі [20].

Зв'язок між вологістю зерна, температурою повітря та відносною вологістю повітря може бути описаний через рівноважну вологість зерна. Для цього широко застосовується модифіковане рівняння Chung–Pfof, наведене в стандарті ASABE D245.7 [18]

$$EMC = -\frac{1}{C} \ln \left( \frac{(T + B) \ln(ERH)}{A} \right), \quad (4)$$

де  $EMC$  — рівноважна вологість зерна на сухій основі;  $ERH$  — рівноважна відносна вологість повітря у частках одиниці;  $T$  — температура;  $A$ ,  $B$ ,  $C$  — емпіричні константи. Рівняння (4) показує, що рівноважна вологість зерна визначається температурою і відносною вологістю повітря, а також видом зерна, оскільки константи  $A$ ,  $B$  і  $C$  є продуктоспецифічними. Саме тому змінні температури повітря, вологості повітря та виду зерна мають пряме фізичне підґрунтя для використання у моделі прогнозування температури зерна [21].

Просторовий розподіл температури в зерновій масі враховується через координату висоти або глибини розташування сенсора. У класичній одномірній постановці зерновий насип по висоті  $H$  поділяється на  $n$  контрольних шарів, а товщина одного шару становить [20]

$$\Delta z = \frac{H}{n}. \quad (5)$$

За такого підходу температура і вологість зерна розглядаються як функції координати  $z$  та часу  $t$ , тобто  $T_g = T_g(z, t)$  і  $W = W(z, t)$ . Отже, глибина встановлення датчика є не допоміжною технічною ознакою, а фізично значущою просторовою координатою, що визначає локальні умови тепло- і вологопереносу в зерновій масі [20].

З урахуванням (1)—(5) набір вхідних змінних, використаних у моделі прогнозування, має чітке фізичне обґрунтування. Поточна температура зерна  $T_g$  характеризує поточний енергетичний стан системи; вологість зерна  $W$  визначає її теплоємність і інтенсивність вологопереносу; температура повітря  $T_a$  та відносна вологість повітря  $RH$  визначають напрям тепло- і масообміну; час після засипки  $\tau$  відображає стадію еволюції процесу; вид зерна задає специфічні сорбційні та теплофізичні властивості; глибина датчика  $z$  характеризує локальне положення в неоднорідному температурному полі зернової маси [20], [21].

За наявності відповідних даних доцільно також додати до моделі ознаку, що характеризує стан аерації або швидкість повітряного потоку. У моделі масообміну міжзернового повітря швидкість повітря входить явно [20]

$$\frac{\partial Y}{\partial t} = -\frac{v_a}{\varepsilon \Delta z} (Y - Y_{in}) + \frac{\rho_g}{\rho_a \varepsilon} R_w, \quad (6)$$

де  $Y$  — абсолютна вологість повітря в міжзерновому просторі;  $Y_{in}$  — абсолютна вологість вхідного повітря;  $v_a$  — швидкість повітря;  $\varepsilon$  — пористість шару;  $\rho_g$  — густина зернової маси;  $\rho_a$  — густина повітря.

Тому для сховищ з активною вентиляцією ознака стану вентиляторів або інтенсивності аерації може підвищити фізичну адекватність прогнозної моделі [20]. До того ж для великих металевих силосів та сховищ з металевим накриттям доцільно розглядати й сонячну радіацію або температури оболонки, оскільки сучасні просторово-часові моделі показують суттєвий вплив зовнішніх теплових навантажень на нагрів верхніх зон зернової маси [22].

### Попередня обробка даних і формування ознак

На першому етапі підготовки даних виконано перетворення часових міток у формат `datetime`, сортування спостережень за ідентифікатором ряду та часом, а також перевірку сталості часового кроку для кожного датчика. За результатами перевірки встановлено, що всі часові ряди мають коректну погодинну структуру без пропусків усередині послідовностей, що забезпечило можливість їх подальшого використання для побудови прогнозних моделей.

Відповідно до постановки задачі для кожного часового ряду сформовано три цільові змінні, які відповідали температурі зерна через один, три та шість часових кроків. Такий підхід дозволив дослідити поведінку моделей у задачі короткострокового прогнозування та порівняти зміну точності зі збільшенням горизонту прогнозування.

Для підвищення інформативності вхідного простору сформовано кілька груп ознак. До першої групи належать лагові ознаки температури зерна, зокрема значення температури на попередніх часових кроках. До другої групи віднесено статистичні ознаки, сформовані на основі ковзних вікон, зокрема ковзні середні та ковзні стандартні відхилення температури зерна. До третьої групи належать часові ознаки, серед яких номер години, день тижня, день року та місяць. Для коректного врахування циклічної природи часу додатково сформовано синусні та косинусні представлення години доби й дня року.

Окрему групу становили фізично змістовні інженерні та просторові ознаки. До них включено різницю між температурою повітря та температурою зерна, оцінені показники вологості зерна, глибину розташування датчика, номер підвіски, номер засіку, тип культури та час після засипки зерна. Такі ознаки дали змогу врахувати не лише часову інерційність процесу, а й просторову неоднорідність температурного поля, відмінності між культурами та стадію збирання зернової маси.

Для задачі прогнозування на 6 годин уперед набір вхідних змінних додатково розширено просторово-режимними ознаками, які описують температурний стан окремого засіку та локальне положення датчика відносно сусідніх точок вимірювання. До таких ознак належали середня температура засіку, стандартне відхилення температури в засіку, відхилення температури датчика від середнього значення по засіку, середня температура по підвісці, відхилення від середнього значення по підвісці, а також вертикальний температурний градієнт. Включення цих характеристик дозволило точніше відобразити просторово-часову структуру процесу та підвищити інформативність моделей для довшого горизонту прогнозування.

Після формування лагових, статистичних, інженерних, просторових і цільових ознак отримано підготовлений модельний датасет, який використовувався в подальших експериментах. Для різних класів моделей застосовувалися відповідні форми подання даних: табличне представлення для моделей множинної лінійної регресії та Compact ANFIS, а також послідовності фіксованої довжини для моделей LSTM і гібридних архітектур LSTM-ANFIS.

Для уникнення витоку інформації розділення даних на навчальну, валідаційну та тестову вибірки виконувалося виключно за часовим принципом. Початкова частина кожного часового ряду використовувалася для навчання, наступна — для валідації, а заключна — для тестування. Такий підхід відповідає реальній постановці задачі прогнозування, у якій майбутні значення є недоступними на момент побудови моделі.

## Кореляційний аналіз вхідних ознак

На етапі підготовки даних виконано перевірку структури часових рядів, формування лагових, статистичних, циклічних, просторових та інженерних ознак, а також побудову трьох цільових змінних для горизонтів прогнозування 1, 3 і 6 годин уперед. Крім базових метеорологічних і часових параметрів, до вхідного простору моделей включено глибину розташування датчика в зерновій масі, час після засипки зерна, тип культури, оцінені показники вологості зерна та похідні температурні характеристики. Це дозволило врахувати просторову неоднорідність температурного поля, особливості культури та стадію зберігання.

Для горизонту прогнозування 1 година вперед найтісніший зв'язок із цільовою змінною продемонстрували поточне значення температури зерна, температура зерна на попередньому часовому кроці, ковзне середнє температури зерна за останні кілька годин, а також інші лагові значення температури зерна. Серед додаткових інформативних ознак вагомий внесок мали різниця між температурою повітря та температурою зерна, циклічні часові ознаки, сонячна радіація, ультрафіолетовий індекс і температура повітря. Це свідчить про виражену інерційність температурної динаміки зернової маси на найкоротшому горизонті прогнозування.

Для горизонту 3 години вперед структура інформативних ознак загалом зберігалася, проте відносна роль поточного значення температури зерна зменшувалася, а значущість інтегральних часових і фізично змістовних ознак зростала. Зокрема, вагомішими ставали ознаки, що описують локальний температурний тренд, різницю між температурою повітря та температурою зерна, оцінені показники вологості зерна, глибину датчика, тип культури та усереднені статистичні характеристики. Така зміна структури зв'язків підтверджує, що зі збільшенням горизонту прогнозування зростає роль нелінійних взаємозв'язків між тепловим станом зерна, зовнішнім середовищем і просторовими особливостями об'єкта.

Для горизонту 6 годин уперед особливого значення набули просторово-режимні ознаки, які характеризують температурний стан засіку та локальне положення датчика відносно сусідніх точок вимірювання. До них належать середня температура засіку, відхилення температури датчика від середнього значення по засіку, відхилення від середнього значення по підвісці, вертикальний температурний градієнт, а також інші агреговані характеристики локального температурного режиму. Зростання інформативності таких ознак свідчить про те, що для довшого горизонту прогнозування недостатньо враховувати лише власну передісторію сигналу, а необхідно також описувати просторову структуру температурного поля зернової маси.

Отримані результати підтвердили доцільність використання як моделей, здатних враховувати часову інерційність процесу, так і моделей нечіткого та гібридного типу, що дають змогу описувати нелінійні взаємозв'язки між температурою зерна, зовнішніми факторами та просторово-режимними характеристиками об'єкта. Кореляційний аналіз і подальший відбір ознак стали основою для побудови моделей множинної лінійної регресії, Compact ANFIS, LSTM та гібридних архітектур LSTM-ANFIS.

## Модель множинної лінійної регресії

Для формування базового рівня порівняння побудовано модель множинної лінійної регресії. Вона використовувалася як baseline-модель, що дозволяє оцінити, наскільки складніші нелінійні та гібридні підходи дійсно забезпечують вигоду у точності прогнозування температури зерна.

До вхідного набору baseline-моделі включено найінформативніші числові ознаки, зокрема поточне значення температури зерна, лаги температури зерна, ковзні статистики, температуру повітря, різницю між температурою повітря та температурою зерна, сонячну радіацію, ультрафіолетовий індекс, циклічні часові ознаки, а також глибину датчика, час після засипки зерна та код культури. Додатково до набору ознак включено оцінені характеристики вологості зерна, що дозволило частково врахувати вплив теплофізичних властивостей зернової маси на її температурну динаміку.

Навчання виконувалося окремо для кожного горизонту прогнозування — 1, 3 і 6 годин уперед. Розбиття на навчальну, валідаційну та тестову вибірки здійснювалося хронологічно, що виключало використання майбутньої інформації під час навчання. Результати baseline-регресії стали основою для подальшого порівняння з моделями Compact ANFIS, LSTM та гібридними архітектурами LSTM-ANFIS.

## Модель Compact ANFIS

Для моделювання нелінійних залежностей між температурою зерна та найінформативнішими

зовнішніми, часовими й просторовими параметрами використано модель Compact ANFIS типу Sugeno першого порядку. На відміну від класичної ANFIS з повним комбінаторним формуванням бази правил, компактна реалізація дозволяє суттєво зменшити обчислювальну складність і зробити модель придатною для роботи з багатофакторним часовим датасетом. У дослідженні standalone-модель Compact ANFIS будувалася окремо для горизонтів прогнозування 1, 3 і 6 годин уперед.

Для кожного горизонту використовувався обмежений набір із семи найінформативніших ознак, відібраних на основі кореляційного аналізу та попередніх експериментів. Вхідний набір формувався з пулу ознак, до якого входили поточне значення температури зерна, її лагові значення, ковзні статистики, різниця між температурою повітря та температурою зерна, температура повітря, сонячна радіація, циклічні часові ознаки, оцінені показники вологості зерна, а також просторові характеристики, зокрема глибина датчика і тип культури. Такий підхід дозволяв обмежити розмір вхідного простору та водночас зберегти найінформативніші змінні для кожного горизонту прогнозування.

Вхідний вектор моделі мав такий вигляд:

$$x = [x_1, x_2, \dots, x_m], \quad (7)$$

де  $m = 7$ . Для compact-реалізації кількість правил обмежувалася значенням  $R = 4$ , що давало змогу уникнути вибухового зростання правила-бази зі збільшенням кількості входів. Antecedent-частина кожного правила задавалася гаусівськими функціями належності

$$\mu_{rj}(x_j) = \exp\left(-\frac{(x_j - c_{rj})^2}{2\sigma_{rj}^2}\right), \quad (8)$$

де  $c_{rj}$  є центром функції належності для  $j$ -ї ознаки в  $r$ -му правилі, а  $\sigma_{rj}$  визначає її розкид.

Параметр розкиду характеризує ширину функції належності: менші значення  $\sigma_{rj}$  формують локальніші правила, тоді як більші — забезпечують ширше покриття простору ознак. Сили спрацювання правил обчислювалися як добуток значень функцій належності для всіх входів, після чого виконувалася їх нормалізація.

Consequent-частина кожного правила задавалася лінійною функцією вхідних змінних

$$f_r(x) = p_{r0} + p_{r1}x_1 + p_{r2}x_2 + \dots + p_{rm}x_m \quad (9)$$

Фінальний прогноз моделі визначався як зважена сума виходів усіх правил

$$\hat{y} = \sum_{r=1}^R w_r f_r(x), \quad (10)$$

де  $w_r$  — нормалізована сила спрацювання  $r$ -го правила.

Формування правил здійснювалося у компактному вигляді на основі кластеризації вхідного простору, а параметри consequent-частини оцінювалися із застосуванням регуляризованої ridge-регресії, що підвищувало стійкість моделі та зменшувало ризик перенавчання. Навчання моделі проводилося окремо для кожного горизонту прогнозування з використанням навчальної та валідаційної вибірок.

Загальний вигляд нечітких правил моделі Compact ANFIS подано в табл. 1.

Таблиця 1

Загальний вигляд нечітких правил моделі Compact ANFIS

№ правила	Antecedent-частина	Consequent-частина
Rule 1	Якщо вхідний вектор $x$ належить локальній області $C_1$ , що визначається гаусівськими функціями належності $\mu_{11}(x_1), \mu_{12}(x_2), \dots, \mu_{1m}(x_m)$	$f_1(x) = p_{10} + p_{11}x_1 + \dots + p_{1m}x_m$
Rule 2	Якщо вхідний вектор $x$ належить локальній області $C_2$ , що визначається гаусівськими функціями належності $\mu_{21}(x_1), \mu_{22}(x_2), \dots, \mu_{2m}(x_m)$	$f_2(x) = p_{20} + p_{21}x_1 + \dots + p_{2m}x_m$
Rule 3	Якщо вхідний вектор $x$ належить локальній області $C_3$ , що визначається гаусівськими функціями належності $\mu_{31}(x_1), \mu_{32}(x_2), \dots, \mu_{3m}(x_m)$	$f_3(x) = p_{30} + p_{31}x_1 + \dots + p_{3m}x_m$
Rule 4	Якщо вхідний вектор $x$ належить локальній області $C_4$ , що визначається гаусівськими функціями належності $\mu_{41}(x_1), \mu_{42}(x_2), \dots, \mu_{4m}(x_m)$	$f_4(x) = p_{40} + p_{41}x_1 + \dots + p_{4m}x_m$

У standalone-моделі Compact ANFIS для кожного горизонту прогнозування використовувалися сім найінформативніших ознак, а кількість правил становила чотири. Для всіх правил застосовувалися гаусівські функції належності, а параметри consequent-частини оцінювалися за допомогою ridge-регресії. У гібридній моделі для горизонту 3 години ANFIS-блок отримував як вхід прогноз LSTM, латентні ознаки  $z_1$  і  $z_2$ , а також фізично інтерпретовані табличні ознаки, зокрема `grain_temp_roll_mean_6`, `temp_minus_grain_temp`, `grain_moisture_base`, `sensor_depth_norm`, `crop_code` і `bin_id_norm`; для цієї конфігурації використовувалися чотири правила, а параметри `sigma_scale` і `ridge_alpha` становили відповідно 1,0 і 3,0. Для горизонту 6 годин у гібридній моделі до входів ANFIS додатково включалися просторово-режимні ознаки `temp_dev_from_bin_mean`, `temp_dev_from_susp_mean` і `susp_grad_bottom_top`; у цій конфігурації також використовувалися чотири правила, а значення `sigma_scale` і `ridge_alpha` становили 0,6 і 0,1.

Такий підхід дав змогу оцінити, наскільки нейро-нечітка модель без рекурентної компоненти здатна враховувати нелінійні взаємозв'язки у даних і як її точність співвідноситься з базовою регресією, LSTM та гібридними моделями LSTM-ANFIS. До того ж та сама компактна нечітка модель надалі використовувалася як коригувальний блок у складі гібридних архітектур, де на її вхід, окрім табличних ознак, подавалися прогнози або латентні ознаки, сформовані LSTM-мережею.

### Модель LSTM

Для врахування часових залежностей у динаміці температури зерна використано модель Long Short-Term Memory. Ця архітектура належить до класу рекурентних нейронних мереж і призначена для роботи з послідовностями спостережень, у яких поточний стан процесу залежить від попередніх значень. На відміну від звичайних рекурентних мереж, LSTM містить механізми керування пам'яттю, що дозволяють зберігати як короткострокові, так і середньострокові залежності в часових рядах та зменшують проблему згасання градієнта під час навчання.

У дослідженні модель LSTM використовувалася для прогнозування температури зерна на горизонтах 1, 3 і 6 годин уперед на основі ковзного часового вікна. Для кожного моменту часу формувалася послідовність вхідних спостережень довжини  $L$ , яка містила значення температури зерна, метеорологічних параметрів та додаткових ознак за попередні часові кроки. Вхідний тензор моделі мав вигляд

$$X_t = [x_{t-L+1}, x_{t-L+2}, \dots, x_t], \quad (11)$$

де  $x_t$  — вектор ознак у момент часу  $t$ , а  $L$  — довжина вхідного часового вікна. Цільовою змінною було майбутнє значення температури зерна  $\hat{y}_{t+h}$ , де  $h \in \{1, 3, 6\}$ .

У вхідний простір LSTM включалися поточне значення температури зерна, основні погодні параметри, різниця між температурою повітря та температурою зерна, циклічні часові ознаки, глибина датчика, оцінка вологості зерна, тип культури та інші інформативні табличні характеристики. Таким чином модель отримувала не лише часову передісторію самої температури зерна, а й зовнішні фактори, що впливають на її зміну. Для різних конфігурацій змінювалися довжина вхідного вікна, кількість ознак, кількість LSTM-блоків, число прихованих нейронів та наявність dropout-регуляризації.

У ході дослідження перевірено кілька конфігурацій LSTM, що відрізнялися довжиною вхідного часового вікна, кількістю ознак і параметрами мережі. Початкові варіанти з довшими часовими вікнами та розширеним набором `engineered features` не забезпечили найкращих результатів. Найефективнішими виявилися компактніші конфігурації з помірною кількістю ознак і коротшими часовими вікнами. Для прогнозу на 1 годину вперед найкращі результати показала standalone-модель з вікном 12 годин, тоді як для горизонту 3 години ефективнішою виявилася модель з вікном 6 годин. Для довшого горизонту 6 годин також досліджено `encoder`-конфігурації LSTM, у яких рекурентна частина мережі використовувалася не лише для формування прогнозу, а й для побудови компактного латентного представлення часової динаміки.

У стандартній конфігурації модель складалася з одного або двох LSTM-шарів, після яких розміщувався повнозв'язний вихідний шар, що формував прогноз температури зерна на відповідний горизонт уперед. У `encoder`-конфігурації перед вихідним шаром додатково формувався `bottleneck`-вектор латентних ознак  $z$ , який надалі використовувався як вхід до нечіткого коригувального блоку в складі гібридних архітектур LSTM-ANFIS. Такий підхід дозволив інтерпретувати LSTM не лише як самостійну прогнозну модель, а і як часовий енкодер, що витягує приховані ознаки з послідовностей спостережень.

Навчання моделей LSTM проводилося з використанням функції втрат Huber, механізмів ранньої зупинки та зменшення швидкості навчання на плато валідаційної помилки, що дозволило стабілізувати процес навчання та зменшити ризик перенавчання. Порівняння кількох конфігурацій показало, що точність LSTM істотно залежить від довжини часового вікна, кількості вхідних ознак і способу використання рекурентної частини моделі. Такий підхід дав змогу оцінити потенціал LSTM як у режимі standalone-прогнозування, так і як базового часового енкодера для подальшої побудови гібридних моделей LSTM-ANFIS.

### Гібридна модель LSTM-ANFIS

Запропоновані гібридні моделі LSTM-ANFIS реалізовано як двоетапні архітектури, у яких поєднуються переваги рекурентного часового моделювання та нечіткого нелінійного доопрацювання прогнозу. На першому етапі LSTM обробляє послідовність вхідних спостережень і формує або первинний прогноз температури зерна на заданий горизонт уперед, або компактне латентне представлення часової динаміки. На другому етапі виходи LSTM використовуються як вхідні ознаки для Compact ANFIS, який разом із табличними, просторовими та режимними характеристиками виконує нелінійне уточнення прогнозованого значення.

У межах дослідження реалізовано кілька варіантів гібридної архітектури. У найпростішій схемі LSTM виступала як базовий прогнозист, а її вихід  $y_{lstm}$  подавався на вхід ANFIS-коректора разом з найінформативнішими табличними ознаками. У residual-варіанті Compact ANFIS навчався не безпосередньо прогнозувати температуру зерна, а оцінювати поправку до прогнозу LSTM, тобто залишкову компоненту. За такого підходу фінальний прогноз обчислювався як

$$\hat{y} = y_{lstm} + \Delta y_{anfis}, \quad (12)$$

де  $y_{lstm}$  — базовий прогноз LSTM, а  $\Delta y_{anfis}$  — поправка, сформована нечітким блоком. Така схема дозволяє розділити часове моделювання та локальну нелінійну корекцію прогнозу.

У складнішій encoder-постановці LSTM використовувалася як часовий енкодер. У цьому випадку, окрім базового прогнозу, з bottleneck-шару мережі отримувалися латентні ознаки  $z_1, z_2$  (а в окремих конфігураціях і додаткові латентні компоненти), які передавалися на вхід ANFIS разом із фізично інтерпретованими табличними параметрами. Це дозволяло нечіткому блоку враховувати не лише явні вхідні ознаки, а й приховані часові закономірності, автоматично виділені рекурентною мережею з послідовностей спостережень. Саме така схема виявилася найефективнішою для горизонту прогнозування 3 години.

Для горизонту 3 години ANFIS-блок у гібридній моделі отримував як вхід прогноз LSTM, латентні ознаки  $z_1$  і  $z_2$ , а також фізично інтерпретовані табличні ознаки, зокрема `grain_temp_roll_mean_6`, `temp_minus_grain_temp`, `grain_moisture_base`, `sensor_depth_norm`, `crop_code` і `bin_id_norm`. Для цієї конфігурації використовувалися чотири нечіткі правила, а параметри `sigma_scale` і `ridge_alpha` становили відповідно 1,0 і 3,0. Для горизонту 6 годин у гібридній моделі до входів ANFIS додатково включалися просторово-режимні ознаки `temp_dev_from_bin_mean`, `temp_dev_from_susp_mean` і `susp_grad_bottom_top`, які описують локальні відхилення температури та вертикальний температурний профіль зернової маси. У цій конфігурації також використовувалися чотири правила, а значення `sigma_scale` і `ridge_alpha` становили 0,6 і 0,1 відповідно.

Структурна схема запропонованої гібридної моделі показана на рис. 3.

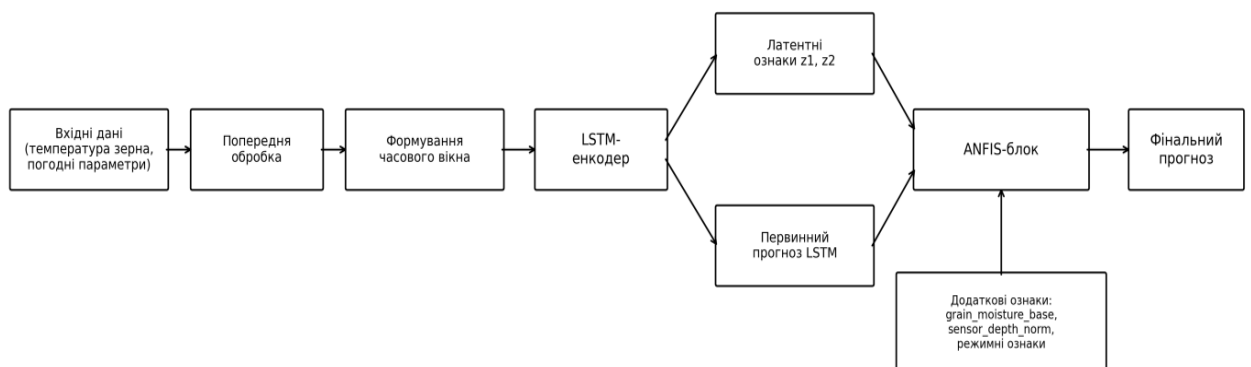


Рис. 3. Структурна схема запропонованої гібридної моделі LSTM-ANFIS

Використання цієї схеми дозволяє поєднати сильні сторони обох класів моделей: LSTM відпо-

відає за виявлення часових закономірностей у послідовностях спостережень, тоді як Contrast ANFIS виконує нелінійну корекцію прогнозу з урахуванням температурної інерції, добової циклічності, впливу зовнішніх погодних факторів і просторового стану зернової маси. Такий підхід дав змогу оцінити доцільність гібридизації для різних горизонтів прогнозування та показати, що зі збільшенням горизонту роль латентних і просторово-режимних ознак зростає.

### Метрики оцінювання

Для оцінювання точності моделей використовувалися три загальноприйняті метрики: середня абсолютна похибка MAE, корінь із середньоквадратичної похибки RMSE та коефіцієнт детермінації  $R^2$ . Метрика MAE характеризує середній абсолютний рівень відхилення прогнозованих значень від фактичних, RMSE є чутливішою до великих похибок, а  $R^2$  дає змогу оцінити частку варіації цільової змінної, що пояснюється моделлю. Таке поєднання метрик дозволяє порівнювати моделі як за абсолютною точністю прогнозування, так і за стійкістю до значних відхилень.

## Результати та обговорення

### Результати кореляційного аналізу

Проведений кореляційний аналіз показав, що для всіх досліджуваних горизонтів прогнозування найінформативнішими є поточне значення температури зерна, її лагові значення та ковзні статистики. Для горизонту 1 година вперед найвищий зв'язок із цільовою змінною мали `grain_temp`, `grain_temp_lag_1`, `grain_temp_roll_mean_3`, `grain_temp_lag_2`, `grain_temp_lag_24` і `grain_temp_lag_3`. До того ж помітну інформативність продемонстрували `hour_cos`, `temp_minus_grain_temp`, `solarradiation`, `uvindex` і `temp`. Це свідчить про те, що на найкоротшому горизонті прогнозування температура зерна визначається насамперед власною інерційністю та поточним тепловим станом системи.

Під час попереднього статистичного аналізу до переліку досліджуваних вхідних параметрів також включено глибину датчика, час після засипки зерна, тип культури та оцінені характеристики вологості зерна як просторово-часові та фізично змістовні характеристики процесу зберігання.

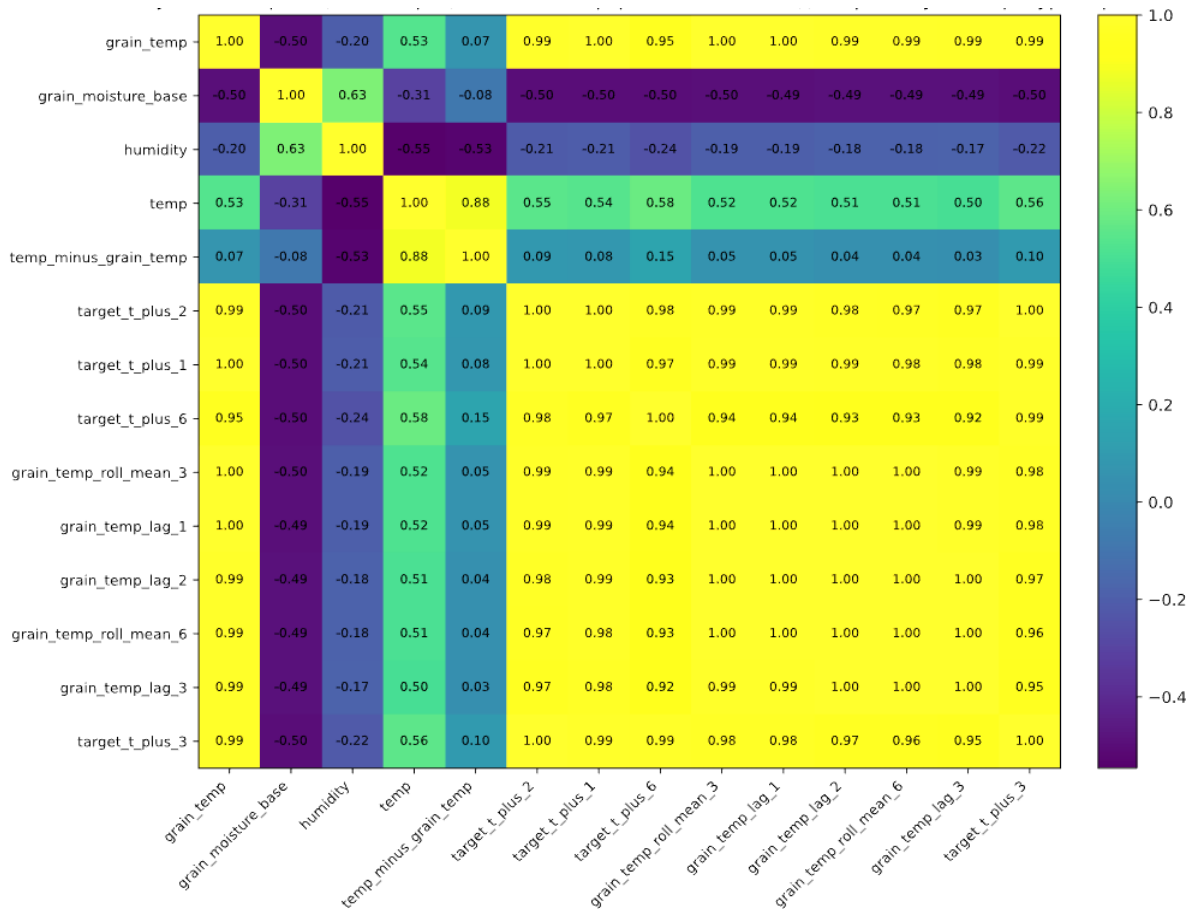


Рис. 4. Кореляційна матриця найбільш інформативних ознак для прогнозу температури зерна

Для горизонту 3 години вперед структура інформативних ознак загалом залишилася подібною, однак вплив поточного значення температури зерна дещо зменшився. Водночас зросла відносна роль ознак, що характеризують зовнішні умови та узагальнені властивості процесу, насамперед  $temp\_minus\_grain\_temp$ ,  $solarradiation$ ,  $temp$ , а також просторових і фізично інтерпретованих параметрів. Для горизонту 6 годин уперед внесок власної передісторії температури зерна залишався суттєвим, проте помітно зростала інформативність просторово-режимних ознак, які описують температурний стан засіку, локальні відхилення температури датчика та вертикальний температурний градієнт у зерновій масі.

Отже, кореляційний аналіз підтвердив дві важливі властивості досліджуваного процесу. По-перше, температура зернової маси характеризується вираженою інерційністю, через що доцільно використовувати часові моделі. По-друге, прогнозована температура залежить не лише від власної передісторії, а й від зовнішніх погодних умов, фізичних характеристик зерна та просторового стану зернової маси, що обґрунтовує застосування нечітких і гібридних підходів для моделювання нелінійних взаємозв'язків.

### Результати baseline-моделей

На першому етапі експериментального дослідження оцінено точність baseline-моделі множинної лінійної регресії. На тестовій вибірці ця модель продемонструвала високі результати для всіх горизонтів прогнозування. Для прогнозу на 1 годину вперед отримано  $MAE = 0,10266$ ,  $RMSE = 0,16233$  та  $R^2 = 0,99228$ . Для горизонту 3 години вперед відповідні значення становили  $MAE = 0,29367$ ,  $RMSE = 0,43842$  та  $R^2 = 0,94355$ , а для горизонту 6 годин вперед —  $MAE = 0,57886$ ,  $RMSE = 0,82781$  та  $R^2 = 0,79831$ .

Отримані результати свідчать, що сформовані лагові, статистичні, часові та інженерні ознаки виявилися достатньо інформативними, а значна частина закономірностей у досліджуваному процесі може бути описана навіть лінійною моделлю. Разом з тим, поступове зниження точності зі збільшенням горизонту прогнозування вказує на зростання складності задачі та необхідність точнішого врахування нелінійних і просторово-режимних залежностей.

Модель Compact ANFIS показала близькі, хоча й дещо гірші результати порівняно з лінійною регресією. Для горизонту 1 година вперед отримано  $MAE = 0,10366$ ,  $RMSE = 0,16288$  та  $R^2 = 0,99223$ , для 3 годин —  $MAE = 0,29999$ ,  $RMSE = 0,44455$  та  $R^2 = 0,94196$ , для 6 годин —  $MAE = 0,60691$ ,  $RMSE = 0,85414$  та  $R^2 = 0,78527$ . Ці результати підтвердили, що нейро-нечітка модель здатна адекватно описувати нелінійні залежності між вхідними параметрами, проте її ефективність істотно залежить від складу вхідних ознак, компактності правила-бази та способу побудови моделі.

### Результати моделей LSTM та вплив довжини часового вікна

Початкові конфігурації LSTM з довгими часовими вікнами не продемонстрували переваги над baseline-підходами. Експерименти показали, що просте збільшення довжини послідовності та розширення набору engineered features не гарантує поліпшення прогнозу. Навпаки, такі конфігурації в окремих випадках призводили до погіршення узагальнювальної здатності моделі, що, ймовірно, пов'язано з перенасиченням мережі надлишковою інформацією та зростанням шумової складової.

Найкращі результати серед чистих рекурентних моделей отримано після переходу до компактніших архітектур і коротших часових вікон. Для горизонту 1 година вперед найкраща standalone LSTM-модель з вікном 12 годин забезпечила  $MAE = 0,11758$ ,  $RMSE = 0,16562$  та  $R^2 = 0,99196$ . Для горизонту 3 години вперед найкращою виявилася конфігурація з вікном 6 годин, яка досягла  $MAE = 0,32393$ ,  $RMSE = 0,42611$  та  $R^2 = 0,94667$ . Для горизонту 6 годин отримано найкращий результат на рівні  $MAE = 0,53255$ ,  $RMSE = 0,74196$  та  $R^2 = 0,83797$  для стабільної encoder-конфігурації LSTM, що використовувалася як база для подальшої гібридизації.

Отже, експериментально встановлено, що оптимальна довжина часового вікна для LSTM залежить від горизонту прогнозування. Для одногодинного прогнозу найпридатнішим є вікно 12 годин, тоді як для 3-годинного прогнозу кращі результати забезпечує вікно 6 годин. Для горизонту 6 годин доцільним виявилася використання LSTM не лише як самостійної прогнозовної моделі, а і як часового енкодера у складі гібридної архітектури.

### Результати гібридної моделі LSTM-ANFIS

На основі найуспішніших конфігурацій LSTM побудовано кілька варіантів гібридної моделі LSTM-ANFIS. У найпростішому випадку гібрид використовував прогноз LSTM як вхід для Compact ANFIS-коректора. У подальших експериментах реалізовано складніші архітектури, у яких

LSTM виконувала функцію часового енкодера, а ANFIS отримував не лише первинний прогноз, а й латентні ознаки, сформовані у bottleneck-шарі. Для горизонту 6 годин до гібридної схеми додатково включалися просторово-режимні ознаки, що описують температурний стан засіку та локальні відхилення температури датчика. Приклад узгодження фактичних і прогнозованих значень температури зерна для однієї з найкращих гібридних моделей показано на рис. 5.




Рис. 5. Порівняння фактичних і прогнозованих значень температури зерна верхнього датчика для гібридної моделі LSTM-ANFIS для горизонту прогнозування 6 годин вперед

Для горизонту прогнозування 1 година вперед найкраща гібридна конфігурація residual Hybrid LSTM → Compact ANFIS забезпечила на тестовій вибірці  $MAE = 0,12283$ ,  $RMSE = 0,17192$  та  $R^2 = 0,99134$ . Для горизонту 3 години вперед найкращий результат продемонструвала архітектура LSTMEncoder + Compact ANFIS, для якої отримано  $MAE = 0,29073$ ,  $RMSE = 0,39682$  та  $R^2 = 0,95375$ . Саме ця конфігурація виявилася найуспішнішою серед усіх досліджених моделей для середнього горизонту прогнозування. Для горизонту 6 годин найкращий результат отримано для моделі LSTMEncoder + Compact ANFIS Residual + Regime Features, яка досягла  $MAE = 0,53045$ ,  $RMSE = 0,73544$  та  $R^2 = 0,84081$ .

Важливо підкреслити, що ефективність гібридизації виявилася різною для різних горизонтів прогнозування. На горизонті 1 година гібридна модель покращувала результати частини standalone LSTM-конфігурацій, проте не змогла перевершити найкращі табличні моделі. Натомість на горизонті 3 години поєднання LSTM-енкодера та Compact ANFIS забезпечило найкращий результат серед усіх досліджених підходів, що підтверджує доцільність використання латентних часових ознак разом із нечітким нелінійним регресором. Для горизонту 6 годин виграв гібридизації став можливим лише після додавання просторово-режимних ознак, які описують стан засіку та вертикальний температурний профіль зернової маси.

Отже, результати дослідження показали, що гібридні моделі LSTM-ANFIS є найдоцільнішими для середнього та довшого горизонтів прогнозування, коли власної часової передісторії сигналу вже недостатньо. Якщо для горизонту 1 година найкращими залишаються табличні моделі, то для горизонтів 3 і 6 годин саме гібридні архітектури дозволили найповніше поєднати переваги часового кодування, нелінійного нечіткого доопрацювання прогнозу та врахування просторово-режимних особливостей об'єкта.

### Порівняльний аналіз моделей

Для узагальнення експериментальних результатів у табл. 2 та на рис. 6 подано порівняння основних моделей за значенням RMSE на навчальній, валідаційній та тестовій вибірках. Такий підхід дозволяє оцінити не лише підсумкову точність прогнозування на відкладених даних, а й узагальнювальну здатність моделей та можливу наявність перенавчання.

Таблиця 2

Порівняння моделей за RMSE на навчальній, валідаційній та тестовій вибірках

Модель	Горизонт прогнозування	Навчальна вибірка	Валідаційна вибірка	Тестова вибірка
Множинна лінійна регресія	1 година	0,133	0,135	0,162
Множинна лінійна регресія	3 години	0,382	0,374	0,438
Множинна лінійна регресія	6 годин	0,739	0,721	0,828
Compact ANFIS	1 година	0,131	0,134	0,163
Compact ANFIS	3 години	0,373	0,367	0,445
Compact ANFIS	6 годин	0,711	0,702	0,854
LSTM	1 година	0,124	0,122	0,166

Модель	Горизонт прогнозування	Навчальна вибірка	Валідаційна вибірка	Тестова вибірка
LSTM	3 години	0,178	0,305	0,426
LSTM	6 годин	0,185	0,637	0,742
LSTM-ANFIS	1 година	0,093	0,121	0,172
LSTM-ANFIS	3 години	0,135	0,264	0,397
LSTM-ANFIS	6 годин	0,162	0,604	0,735




Рис. 6. Порівняння моделей прогнозування температури зерна за показником RMSE на навчальній, валідаційній та тестовій вибірках для горизонтів 1, 3 і 6 годин уперед

Як випливає з наведених результатів, співвідношення між значеннями RMSE на навчальній, валідаційній та тестовій вибірках дає змогу оцінити стабільність моделей під час переходу від навчальних даних до відкладеної тестової вибірки. Для прогнозу на 1 годину вперед найкращою за тестовим RMSE залишилася модель множинної лінійної регресії, що свідчить про високу інформативність

сформованих лагових, статистичних та інженерних ознак на надкороткостроковому горизонті. Для горизонту 3 години найкращий результат продемонструвала гібридна архітектура LSTMEncoder + Compact ANFIS, а для горизонту 6 годин — модель LSTMEncoder + Compact ANFIS Residual + Regime Features. Порівняння значень RMSE на трьох вибірках показує, що зі збільшенням горизонту прогнозування зростає складність задачі, а також роль моделей, здатних поєднувати часові, нелінійні та просторово-режимні залежності.

Додаткове наведення результатів на навчальній та валідаційній вибірках дозволило перевірити, чи зумовлені отримані тестові показники стійкою узагальнювальною здатністю моделей, а не лише випадковими особливостями тестового набору. Для табличних моделей значення RMSE на навчальній, валідаційній та тестовій вибірках змінювалися відносно послідовно, що свідчить про стабільність їх роботи за хронологічного розділення даних. Для LSTM та гібридних LSTM-ANFIS-моделей, особливо на горизонтах 3 і 6 годин, спостерігалось помітніше зростання похибки під час переходу від навчальної до валідаційної та тестової вибірок. Це вказує на ускладнення задачі узагальнення для рекурентних і гібридних архітектур на довших горизонтах, проте саме ці моделі забезпечили найнижчий тестовий RMSE для прогнозування на 3 і 6 годин уперед.

Аналогічна тенденція спостерігалася і за показником MAE: для горизонту 1 година найкращий результат продемонструвала множинна лінійна регресія (MAE = 0,10266), для горизонту 3 години — гібридна модель LSTMEncoder + Compact ANFIS (MAE = 0,29073), а для горизонту 6 годин — модель LSTMEncoder + Compact ANFIS Residual + Regime Features (MAE = 0,53045). Отримані результати дозволяють підсумувати, що доцільність застосування тієї чи іншої моделі визначається горизонтом прогнозування. Для надкороткострокового прогнозу достатньо інформативними виявилися табличні ознаки, що забезпечило перевагу множинної лінійної регресії. Натомість для горизонтів 3 і 6 годин перевага перейшла до гібридних архітектур LSTM-ANFIS, які змогли ефективніше використати як часову структуру сигналу, так і фізично змістовні табличні та просторові характеристики об'єкта.

### Обговорення результатів

Результати дослідження показали, що точність прогнозування температури зерна значною мірою визначається не лише типом моделі, а й способом подання вхідної інформації. Дуже високі результати baseline-регресії пояснюються тим, що до її входу включено лагові значення температури зерна, ковзні статистики, різницю між температурою повітря і температурою зерна, циклічні часові ознаки, а також фізично змістовні просторові характеристики. У такому випадку значна частина структури задачі вже явно закладена у вхідні дані, що особливо важливо для горизонту 1 година вперед.

Початкові рекурентні моделі не завжди перевершували baseline-підходи, що свідчить про те, що сама по собі LSTM не гарантує переваги у задачах з відносно обмеженим часовим обсягом даних і добре підготовленими табличними ознаками. Лише після підбору довжини часового вікна, скорочення вхідного простору та переходу до encoder-постановки вдалося отримати суттєве покращення якості прогнозу. Це показує, що ефективність рекурентних моделей у задачі прогнозування температури зерна є чутливою до конфігурації часової пам'яті та способу інтеграції часових ознак з табличними параметрами.

Гібридизація LSTM і Compact ANFIS виявилася найефективнішою не для найкоротшого, а для середнього та довшого горизонтів прогнозування. Для горизонту 3 години поєднання LSTM-енкодера та Compact ANFIS забезпечило найкращий результат серед усіх досліджених моделей. Для горизонту 6 годин перевага гібридної моделі стала можливою лише після введення просторово-режимних ознак, які описують температурний стан засіку, локальні відхилення температури датчика та вертикальний температурний градієнт. Це дає підстави вважати, що в подібних задачах гібридні моделі є найдоцільнішими тоді, коли прогнозування виходить за межі надкороткого горизонту і потребує одночасного врахування часової динаміки, нелінійних залежностей і просторової структури температурного поля.

### Висновки

У статті досліджено задачу короткострокового прогнозування температури зерна у зерносковищах на основі моделей множинної лінійної регресії, Compact ANFIS, LSTM та гібридних архітектур LSTM-ANFIS. Для цього сформовано багатосерійний часовий датасет, що охоплює дві зернові культури, чотири засіки, 24 підвіски та 72 датчики, а також містить зовнішні метеорологічні

параметри, просторові характеристики та інженерні ознаки як фактори впливу на температурний режим зернової маси.

У результаті попереднього аналізу даних встановлено, що найінформативнішими для прогнозування є поточне значення температури зерна, її лагові значення, ковзні статистики, різниця між температурою повітря та температурою зерна, а також циклічні часові, просторові та фізично змістовні ознаки. Проведений кореляційний аналіз підтвердив виражену інерційність температурного стану зернової маси та наявність впливу зовнішнього середовища, що обґрунтовує доцільність використання як часових, так і нечітких моделей.

Експериментальні дослідження показали, що ефективність моделі істотно залежить від горизонту прогнозування. Для горизонту 1 година найкращі результати продемонструвала baseline-модель множинної лінійної регресії, яка досягла MAE = 0,10266 та RMSE = 0,16233. Це свідчить про те, що правильно сформовані лагові, статистичні та інженерні ознаки вже містять значну частину інформації, необхідної для ефективного надкороткострокового прогнозування температури зерна. Для цього самого горизонту Compact ANFIS і standalone LSTM показали близькі результати, проте не перевершили лінійну регресію.

Дослідження кількох конфігурацій LSTM показало, що точність рекурентної моделі істотно залежить від довжини часового вікна, складу вхідних ознак і способу використання мережі. Для горизонту 3 години найкращий результат серед усіх досліджених моделей забезпечила гібридна архітектура LSTMEncoder + Compact ANFIS, яка досягла MAE = 0,29073, RMSE = 0,39682 та  $R^2 = 0,95375$ . Це підтверджує доцільність поєднання часового енодера LSTM з нечітким нелінійним регресором на середньому горизонті прогнозування, коли власної передісторії сигналу вже недостатньо для найточнішого прогнозу.

Для горизонту 6 годин найкращий результат отримано для моделі LSTMEncoder + Compact ANFIS Residual + Regime Features, яка досягла MAE = 0,53045, RMSE = 0,73544 та  $R^2 = 0,84081$ . Перевага цієї моделі пояснюється тим, що до її входу включено не лише часові та табличні ознаки, а й просторово-режимні характеристики, які описують температурний стан засіку, локальні відхилення температури датчика та вертикальний температурний градієнт у зерновій масі. Отже, для довшого горизонту прогнозування гібридизація виявилася ефективною лише за умови врахування просторової структури температурного поля.

Отримані результати дозволяють підсумувати, що гібридні архітектури LSTM-ANFIS не є універсально найкращими для всіх режимів прогнозування, проте вони виявляються найдоцільнішими для горизонтів 3 і 6 годин, тоді як для горизонту 1 година достатньо інформативною є таблична регресійна модель. Практичне значення отриманих результатів полягає у можливості використання запропонованого підходу в системах моніторингу зерносховищ для своєчасного виявлення небезпечних температурних тенденцій і підтримки рішень щодо керування мікрокліматом.

Перспективи подальших досліджень пов'язані з розширенням датасету за тривалістю спостережень, включенням додаткових технологічних параметрів зберігання, перевіркою роботи моделей на більшій кількості культур, а також удосконаленням гібридних архітектур за рахунок адаптивного добору вхідних ознак і інтеграції прогнозних моделей у багатоагентні системи керування мікрокліматом зерносховищ.

## СПИСОК ВИКОРИСТАНОЇ ЛІТЕРАТУРИ

- [1] Q. Wang, J. Feng, F. Han, W. Wu, and S. Gao, "Analysis and prediction of grain temperature from air temperature to ensure the safety of grain storage," *International Journal of Food Properties*, vol. 23, no. 1, pp. 1200-1213, 2020. <https://doi.org/10.1080/10942912.2020.1792922>.
- [2] S. Duan, W. Yang, X. Wang, S. Mao, and Y. Zhang, "Grain Pile Temperature Forecasting from Weather Factors: A Support Vector Regression Approach," in *2019 IEEE/CIC International Conference on Communications in China (ICCC)*, Changchun, China, 2019, pp. 255-260. <https://doi.org/10.1109/ICCCChina.2019.8855910>.
- [3] L. Ge, C. Chen, Y. Li, T. Mo, and W. Li, "A CNN-based temperature prediction approach for grain storage," *International Journal of Internet Manufacturing and Services*, vol. 7, no. 4, pp. 345-357, 2020. <https://doi.org/10.1504/IJIMS.2020.110234>.
- [4] S. Duan, W. Yang, X. Wang, S. Mao, and Y. Zhang, "Deep Spatio-Temporal Attention Model for Grain Storage Temperature Forecasting," in *2020 IEEE 26th International Conference on Parallel and Distributed Systems (ICPADS)*, 2020, pp. 593-600. <https://doi.org/10.1109/ICPADS51040.2020.00082>.
- [5] S. Duan, W. Yang, X. Wang, S. Mao, and Y. Zhang, "Temperature Forecasting for Stored Grain: A Deep Spatiotemporal Attention Approach," *IEEE Internet of Things Journal*, vol. 8, no. 23, pp. 17147-17160, Dec. 2021. <https://doi.org/10.1109/IJOT.2021.3078332>.
- [6] Q. Wang, M. Hou, Y. Qin, and F. Lian, "Temperature Forecasting of Grain in Storage: An Improved Approach Based on Broad Learning Network," *IEEE Access*, vol. 12, pp. 115112-115123, 2024. <https://doi.org/10.1109/ACCESS.2024.3417533>.

- [7] Q. Zhang, W. Zhang, Q. Huang, C. Wan, and Z. Li, "AMSformer: A Transformer for Grain Storage Temperature Prediction Using Adaptive Multi-Scale Feature Fusion," *Agriculture*, vol. 15, no. 1, p. 58, 2025. <https://doi.org/10.3390/agriculture15010058>.
- [8] X. Li, W. Wu, H. Guo, X. Qiao, Y. Lu, Y. Wu, and G. Qiao, "An Interpretable Temperature Prediction Method for Grain in Storage Based on Improved Temporal Fusion Transformers," *SSRN*, 2024. <https://doi.org/10.2139/ssrn.4937130>.
- [9] H. Cui, Q. Zhang, W. Zhang, Z. Wu, and W. Wu, "Modeling and Application of Temporal Correlation of Grain Temperature during Grain Storage," *Agriculture*, vol. 12, no. 11, p. 1883, 2022. <https://doi.org/10.3390/agriculture12111883>.
- [10] H. Cui, Q. Zhang, J. Zhang, Z. Wu, and W. Wu, "Classification of Grain Storage Inventory Modes Based on Temperature Contour Map of Grain Bulk Using Back Propagation Neural Network," *Agriculture*, vol. 11, no. 5, p. 451, 2021. <https://doi.org/10.3390/agriculture11050451>.
- [11] Y. Jin, K. W. Wong, D. Yang, Z. Zhang, W. Wu, and J. Yin, "A neural network model used in continuous grain dryer control system," *Drying Technology*, vol. 40, no. 9, pp. 1901-1922, 2022. <https://doi.org/10.1080/07373937.2021.1891930>.
- [12] K. V. Shihabudheen and G. N. Pillai, "Recent advances in neuro-fuzzy system: A survey," *Knowledge-Based Systems*, vol. 152, pp. 136-162, 2018. <https://doi.org/10.1016/j.knosys.2018.04.014>.
- [13] M. N. M. Salleh, N. Talpur, and K. Hussain, "Adaptive Neuro-Fuzzy Inference System: Overview, Strengths, Limitations, and Solutions," in *Data Mining and Big Data*, Y. Tan, H. Takagi, and Y. Shi, Eds. Cham, Switzerland: Springer, 2017, pp. 527-535. [https://doi.org/10.1007/978-3-319-61845-6\\_52](https://doi.org/10.1007/978-3-319-61845-6_52).
- [14] A. R. Sadeghian, "Nonlinear neuro-fuzzy prediction: methodology, design and applications," in *Proc. 10th IEEE Int. Conf. Fuzzy Systems*, Melbourne, VIC, Australia, 2001, vol. 3, pp. 1022-1026. <https://doi.org/10.1109/FUZZ.2001.1009136>.
- [15] D. Kukolj, "Design of adaptive Takagi-Sugeno-Kang fuzzy models," *Applied Soft Computing*, vol. 2, no. 2, pp. 89-103, 2002. [https://doi.org/10.1016/S1568-4946\(02\)00032-7](https://doi.org/10.1016/S1568-4946(02)00032-7).
- [16] X. Gu, F.-L. Chung, and S. Wang, "Bayesian Takagi-Sugeno-Kang fuzzy classifier," *IEEE Transactions on Fuzzy Systems*, vol. 25, no. 6, pp. 1655-1671, Dec. 2017. <https://doi.org/10.1109/TFUZZ.2016.2617377>.
- [17] О. В. Бондарчук, О. В. Мазурук, і В. Б. Мокін, «Системний аналіз та прогнозування температури зерна у силосі зернового елеватора за даними IoT-системи з використанням технологій штучного інтелекту,» у *Матеріалах Всеукраїнської науково-практичної інтернет-конференції «Молодь в науці: дослідження, проблеми, перспективи (МН-2025)»*, 15–16 червня 2025 р. <https://conferences.vntu.edu.ua/index.php/mn/mn2025/paper/view/25196>
- [18] А. В. Святобатько, і І. О. Фурман, «Нейромережевий метод прогнозування параметрів зернової маси, що зберігається у бункерах елеваторів,» *Енергетика та комп'ютерно-інтегровані технології в АПК*, no. 1, pp. 68-70, 2014. [Електронний ресурс]. Режим доступу: [http://www.irbis-nbuv.gov.ua/cgi-bin/irbis\\_nbuv/cgiirbis\\_64.exe?Z21ID=&I21DBN=UJRN&P21DBN=UJRN&S21STN=1&S21REF=10&S21FMT=fullwebr&C21COM=S&S21CNR=20&S21P01=0&S21P02=0&S21P03=A=&S21COLORTERMS=1&S21STR=%D0%A4%D1%83%D1%80%D0%BC%D0%B0%D0%BD%20%D0%86\\$](http://www.irbis-nbuv.gov.ua/cgi-bin/irbis_nbuv/cgiirbis_64.exe?Z21ID=&I21DBN=UJRN&P21DBN=UJRN&S21STN=1&S21REF=10&S21FMT=fullwebr&C21COM=S&S21CNR=20&S21P01=0&S21P02=0&S21P03=A=&S21COLORTERMS=1&S21STR=%D0%A4%D1%83%D1%80%D0%BC%D0%B0%D0%BD%20%D0%86$).
- [19] А. В. Святобатько, А. Хоховські, П. Обставські, and І. О. Фурман, «Розробка архітектури програмно-апаратного комплексу засобів контролю та прогнозування параметрів зернової маси, що зберігається у бункерах на елеваторі,» *Вісник ХНТУСГ ім. Петра Василенка. Технічні науки*, no. 165, pp. 42-43, 2015. [Електронний ресурс]. Режим доступу: <https://www.irbis-nbuv.gov.ua>
- [20] A. Iguaz, C. Arroqui, A. Esnoz, and P. Vírveda, "Modelling and Simulation of Heat Transfer in Stored Rough Rice with Aeration," *Biosystems Engineering*, vol. 89, no. 1, pp. 69-77, 2004. <https://doi.org/10.1016/j.biosystemseng.2004.05.001>
- [21] ASABE, "Moisture Relationships of Plant-Based Agricultural Products," *ASAE D245.7 JUN2021*, St. Joseph, MI, USA: American Society of Agricultural and Biological Engineers, 2021.
- [22] F. I. Molina-Herrera, L. I. Quemada-Villagómez, M. Calderón-Ramírez, G. M. Martínez-González, and H. Jiménez-Islas, "Modeling Temperature and Moisture Dynamics in Corn Storage Silos: A Comparative 2D and 3D Approach," *Modelling*, vol. 6, no. 1, art. 7, 2025. <https://doi.org/10.3390/modelling6010007>.

Рекомендована кафедрою комп'ютерних систем управління ВНТУ

Дата надходження 24.04.2026

Дата прийняття до друку після рецензування 5.05.2026

Дата публікації 7.07.2026

Ця робота ліцензується відповідно до

[Creative Commons Attribution 4.0 International License](https://creativecommons.org/licenses/by/4.0/)

**Ліщук Андрій Романович** — аспірант кафедри комп'ютерних систем управління, e-mail: a.r.lishchuk@gmail.com . <https://orcid.org/0009-0003-5519-456X>;

**Дубовой Володимир Михайлович** — д-р. техн. наук, професор кафедри комп'ютерних систем управління, e-mail: v.m.dubovoy@gmail.com . <https://orcid.org/0000-0003-0440-3643>.

Вінницький національний технічний університет, Вінниця

## Comparative Analysis of Short-Term Grain Temperature Forecasting Models in Grain Storages

<sup>1</sup>Vinnitsia National Technical University

*Short-term forecasting of grain temperature is an important component of intelligent monitoring of grain storage facilities, since it enables the timely detection of dangerous temperature trends, assessment of the risk of local self-heating of the grain mass, and improvement of decision-making efficiency during storage. The temperature state of grain is formed under the influence of the thermal inertia of the grain mass, external meteorological conditions, moisture-related processes, crop type, sensor depth, and spatial heterogeneity of the temperature field. Therefore, it is relevant to study forecasting models that can take into account both the temporal dynamics of the process and nonlinear relationships between meteorological, technological, spatial, and regime-related parameters.*

*This paper investigates multiple linear regression, LSTM, Compact ANFIS, and hybrid LSTM-ANFIS architectures for short-term forecasting of grain temperature at prediction horizons of 1, 3, and 6 hours ahead. The study was carried out using a multi-series time dataset that includes two grain crops, four bins, 24 sensor suspensions, and 72 temperature sensors. The input data contained hourly measurements of grain temperature, external meteorological parameters, sensor location characteristics, and additional engineered features. During data preprocessing, lag, statistical, cyclic, spatial, and mode-related features were generated, as well as target variables for each prediction horizon. To prevent information leakage, the dataset was divided into training, validation, and test subsets according to the chronological principle.*

*The correlation analysis showed that the most informative features for grain temperature forecasting are the current grain temperature, its lagged values, rolling statistics, the difference between ambient air temperature and grain temperature, estimated grain moisture, crop type, sensor depth, and spatial-regime characteristics. It was shown that model performance depends significantly on the prediction horizon. For the 1-hour horizon, the best result was achieved by the multiple linear regression model, which provided MAE = 0.10266, RMSE = 0.16233, and  $R^2 = 0.99228$ . For the 3-hour horizon, the highest accuracy was demonstrated by the hybrid LSTMEncoder + Compact ANFIS model, with MAE = 0.29073, RMSE = 0.39682, and  $R^2 = 0.95375$ . For the 6-hour horizon, the best performance was achieved by the LSTMEncoder + Compact ANFIS Residual + Regime Features model, which reached MAE = 0.53045, RMSE = 0.73544, and  $R^2 = 0.84081$ .*

*The obtained results confirm that, for ultra-short-term grain temperature forecasting, tabular models with properly generated lag, statistical, and engineered features may be sufficiently effective. At the same time, as the prediction horizon increases, the use of hybrid architectures becomes more appropriate. Such models combine the ability of LSTM to capture temporal dependencies with the capability of Compact ANFIS to perform nonlinear forecast refinement based on physically meaningful and spatial-regime features. The practical significance of the proposed approach lies in its potential application in grain storage monitoring systems, early warning of dangerous temperature changes, and decision support for microclimate control in stored grain.*

**Keywords:** grain temperature forecasting; grain storage facility; short-term forecasting; multiple linear regression; LSTM; ANFIS; hybrid model; time series.

**Lishchuk Andrii R.** — Post-Graduate Student of the Chair of Computer Control Systems, e-mail: a.r.lishchuk@gmail.com . <https://orcid.org/0009-0003-5519-456X>;

**Dubovoi Volodymyr M.** — Dr. Sc. (Eng.), Professor, Professor of the Chair of Computer Control Systems, e-mail: v.m.dubovoy@gmail.com . <https://orcid.org/0000-0003-0440-3643>