



---

---

2022

# НАУКОВІ ПРАЦІ НАЦІОНАЛЬНОГО УНІВЕРСИТЕТУ ХАРЧОВИХ ТЕХНОЛОГІЙ

**Том 28 № 1**

*Журнал  
«Наукові праці Національного університету харчових технологій»  
видається з 1938 року*

КИЇВ ✦ НУХТ ✦ 2022

## ЗМІСТ

### Автоматизація та інформаційні технології

Лисенко В. П., Поліщук Д. В., Засць Н. А. Машинне навчання в сценаріях керування температурно-вологісним режимом для тепличних комплексів

### Біотехнології

Скροцька О. І., Лазюка Ю. В., Харченко С. В. Наночастки срібла та золота: практичне застосування, біосинтез з використанням дріжджів, біологічна активність

### Економіка, менеджмент і маркетинг

Грущенко А. В., Степанчук С. О. Особливості застосування інтернет-реклами та PR закладу харчування ТОВ «Домінос Піцца Юкрейн»

Гринюк Ю. М. HR-навігатор з антидискримінаційного законодавства на етапі пошуку та підбору кандидатів

Кундієєва Г. О., Тур О. В. Мікроекономічний аналіз ринку ковбасних виробів: попит

Яремич Г. С. Методи управління конфліктами в організації

### Механічна та електрична інженерія

Зінкевич П. О., Балута С. М., Куєвда Ю. В. Порівняльний аналіз методів короткострокового багатокрокового прогнозування електричного навантаження

Михайлов В. М., Загорулько А. М., Загорулько О. Є. Інтенсифікація процесів концентрування та ІЧ-сушіння рослинної сировини

Петренко В. П., Масліков М. О., Бойко В. О., Мирошник М. М. Швидкість температурних релаксацій на випарних установках у перехідних режимах

Філоненко В. М. Рециркуляційна система регулювання подачі відцентрового насоса: науково-технічні аспекти реалізації

### Харчові технології

Павлюченко О. С., Дейниченко Л. Г., Кравчук А. В., Матіяшчук О. В., Силка І. М. Теоретичне і практичне обґрунтування рецептурного складу мафінів яблучних спеціального призначення

Бужанська М. В., Ощиток І. М. Фізико-хімічні властивості крохмалю та крохмалепродуктів як перевага їхнього використання в харчовій промисловості

Адамчук Л. О. Мелісопалінологічні дослідження медів з Українських Карпат

Сімахіна Г. О., Науменко Н. В. Використання ягід чорної смородини для виробництва порошкоподібних дієтичних добавок

## CONTENTS

### Automation and Information Technologies

7 Lysenko V., Polishchuk D., Zaiets N. Machine learning in scenarios of control of temperature-humidity regime for greenhouse complexes

### Biotechnologies

18 Skrotska O., Laziuka Y., Kharchenko Y. Silver and gold nanoparticles: practical application, biosynthesis using yeast, bioactivity

### Economy, Management and Marketing

32 Hrushchenko A., Stepanchuk S. Features of using internet advertising and PR establishment of LLC "Domino's Pizza Ukraine"

47 Hryniuk Y. HR-navigator on anti-discrimination legislation at the stage of searching and selection of candidates

57 Kundieieva H., Tur O. Microeconomic analysis of the sausage market: demand

67 Yaremich A. Conflict management methods in the organization

### Mechanical and Electrical Engineering

77 Zinkevych P., Baluta S., Kuievda Iu. Comparative analysis of methods of short-term multi-term forecasting of electric load

93 Mykhaylov V., Zahorulko A., Zagorulko O. Intensification of concentration and IR-drying processes of vegetable raw materials

104 Petrenko V., Maslikov M., Boyko V., Miroshnik M. Speed of temperature relaxations on evaporatory installations in transitional modes

117 Filonenko V. Recirculation system of adjusting by centrifugal pump: scientific and technical aspects of realization

### Food Technologies

134 Pavluchenko O., Deinychenko L., Kravchuk A., Matiyashchuk O., Sylka I. Theoretical and practical prescription justification of apple muffins for special purpose

145 Buzhanska M., Oshchypok I. Physico-chemical properties of starch and starch products as an advantage of their use in food industry

154 Adamchuk L. Melissopalynological studies on honeys from the ukrainian carpathians

165 Simakhina G., Naumenko N. Using the black currant berries for production of powderaceous dietetic supplements

## COMPARATIVE ANALYSIS OF METHODS OF SHORT-TERM MULTI-TERM FORECASTING OF ELECTRIC LOAD

P. Zinkevych, S. Baluta, Iu. Kuievda  
*National University of Food Technologies*

---

**Key words:**

*ANFIS*  
*ARIMA*  
*“Naive” predicting*  
*Multi-step short-term PEL*  
*Predicting methods*

---

**Article history:**

Received 14.01.2022  
Received in revised form  
28.01.2022  
Accepted 10.02.2022

---

**Corresponding author:**

S. Baluta  
**E-mail:**  
epem2011@ukr.net

---

**ABSTRACT**

Multi-step predicting of electrical load (PEL) allows to predict multi-stage electricity consumption in the future. Multi-step PEL is used to control power consumption and ensure energy-efficient modes of operation of power supply systems of industrial and civil facilities. This paper investigates mathematical models based on statistical methods and artificial intelligence methods for predicting the electrical load (PEL) of industrial enterprises for many steps forward.

A review of the literature sources showed that a relatively small number of statistical and artificial intelligence methods were developed for multi-step short-term PEL. The most promising PEL methods which provide the highest prediction accuracy are the following: autoregressive integrated moving average model (ARIMA) and adaptive neuro-fuzzy inference system (ANFIS). To compare the ARIMA and ANFIS methods, a statistical method was chosen: “naive” predicting. In order to select the PEL method which will solve the problems of power consumption and power supply management, calculation studies were conducted using these PEL methods. A feature of predicting using ANFIS is to take into account such an exogenous factor as time of day.

The object of the study are PEL methods, which were carried out on the basis of measured data of electrical load of an industrial enterprise for the manufacture of plastic products. Measurements were performed daily from April 1, 2015 to May 1, 2015 (including holidays and weekends) every half an hour (48 measurements per day, respectively). To assess the quality of predicting models, a standard value was used: standard error (RMSE) and average absolute error (MAPE). Calculation studies were performed using the software MATLAB 2020b, with a set of tools: Fuzzy Logic Toolbox and Econometrics Toolbox.

PEL models for multi-step PEL were developed using ARIMA methods, a “naive” predicting and an adaptive ANFIS system. The results of computational studies showed that the prediction using the ARIMA model (4,1,2) for the test sample provides the smallest error RMSE 0.052 and MAPE error 0.035. In further research it is planned to develop models for predicting electricity generation by photovoltaic power plants (PPP) with intelligent control systems.

## ПОРІВНЯЛЬНИЙ АНАЛІЗ МЕТОДІВ КОРОТКОСТРОКОВОГО БАГАТОКРОКОВОГО ПРОГНОЗУВАННЯ ЕЛЕКТРИЧНОГО НАВАНТАЖЕННЯ

П. О. Зінькевич, С. М. Балюта, Ю. В. Куєвда

Національний університет харчових технологій

Багатокрокове прогнозування електричного навантаження (ПЕН) дає змогу передбачити багатоетапне споживання електроенергії в майбутньому. Багатокрокове ПЕН використовується для керування електроспоживанням і забезпечення енергоефективних режимів функціонування систем електрозабезпечення промислових і цивільних об'єктів.

У статті досліджено математичні моделі на основі статистичних методів і методів штучного інтелекту для прогнозування електричного навантаження (ПЕН) промислових підприємств на багато кроків уперед. Опрацювання літератури показало, що для багатокрокового короткострокового ПЕН розроблено відносно невелику кількість статистичних методів і методів штучного інтелекту. Найбільш перспективними методами ПЕН, які забезпечують точність прогнозування можна вважати такі: авторегресивна інтегрована модель ковзного середнього (ARIMA) та адаптивна система нейро-нечіткого висновку (ANFIS). Для порівняння методів ARIMA та ANFIS було вибрано статистичний метод: «наївний» прогноз. З метою вибору методу ПЕН, який найбільшою мірою забезпечить вирішення завдань керування електроспоживанням та електропостачанням, були проведені розрахункові дослідження з використанням вказаних методів ПЕН. Особливістю прогнозування з використанням ANFIS є врахування такого екзогенного фактора, як час доби.

Об'єктом дослідження є методи ПЕН, які проводилися на основі вимірних даних електричного навантаження промислового підприємства з виготовлення пластмасових виробів. Вимірювання проводилися щоденно з 01 квітня 2015 року по 01 травня 2015 року (з урахуванням святкових та вихідних днів) що пів години (відповідно 48 вимірювань на добу). Для оцінки якості моделей прогнозування використовувалися стандартні величини: середньоквадратична похибка (RMSE) та середня абсолютна похибка (MAPE). Розрахункові дослідження виконані у програмному середовищі MATLAB 2020b з набором інструментів: Fuzzy Logic Toolbox та Econometrics Toolbox.

З використанням методів ARIMA, «наївного» прогнозу та адаптивної системи ANFIS розроблені моделі ПЕН для багатокрокового ПЕН. Результати розрахункових досліджень показали, що прогнозування з використанням моделі ARIMA (4,1,2) для тестової вибірки забезпечує найменшу похибку RMSE — 0,052, похибка MAPE — 0,035. У подальших дослідженнях планується розробка моделей прогнозування вироблення електроенергії фотоелектростанціями (ФЕС) з інтелектуальними системами керування.

**Ключові слова:** ANFIS, ARIMA, «наївний» прогноз, багатокрокове короткострокове ПЕН, методи прогнозування.

**Постановка проблеми.** Короткострокове прогнозування навантаження (STLF) — один із найважливіших етапів ефективного управління електроспоживанням та електропостачанням промислових і цивільних об'єктів. Прогнозування можна розділити на дві категорії за кількістю кроків: однокрокове прогнозування та багатокрокове прогнозування. Однокрокове прогнозування передбачає використання історичних змінних, пов'язаних із споживанням електроенергії, для прогнозування наступного одноетапного кроку. Багатокрокове прогнозування передбачає майбутнє багатоетапне споживання електроенергії (Shao & Kim, 2020). На сьогодні більшість сучасних досліджень зосереджується лише на однокроковому прогнозуванні (STLF), а багатокрокове прогнозування потребує проведення додаткових досліджень. У цій статті розглядаються методи багатокрокового короткострокового ПЕН для промислових підприємств і цивільних об'єктів.

**Аналіз останніх досліджень і публікацій.** Для багатокрокового короткострокового ПЕН існує не такий широкий вибір статистичних методів і методів штучного інтелекту. На відміну від прогнозування на один крок вперед, завдання прогнозування на багато кроків вперед більш складні (An & Anh, 2015), оскільки при такому прогнозуванні мають справу з такими додатковими ускладненнями, як накопичення помилок, зниження точності прогнозу (Taieb, Bontempi, Atiya & Sorjamaa, 2012). У цьому розділі виконано короткий огляд дослідницьких праць з розробки методів багатокрокового ПЕН.

У (Tau, Muwafaq, Tiong & Chou, 2019) досліджено дані споживання електроенергії із січня 2009 року по грудень 2018 року. Мета дослідження полягала в тому, щоб виконати багатокрокове ПЕН на 2019 рік. Для цього був використаний метод ANFIS. Прогнозування з ANFIS дає MAPE між фактичним і прогнозованим споживанням електроенергії 0,402%, що набагато краще, ніж при використанні таких методів, як моделі часових рядів Холта-Вінтерса, множинної лінійної регресії MLR та нечітких часових рядів першого порядку FTS, які забезпечують MAPE, відповідно, 11,14%, 10,62% та 5,74%.

У (Jain, Quamer & Pamula, 2018) зроблено прогнозування споживання електроенергії за допомогою моделі ARIMA. Представлена модель забезпечує MAPE 6,63%. Тож модель ARIMA має потенціал конкурувати з існуючими методами ПЕН.

У дослідженні (Saravanan, Kannan & Thangaraj, 2015) запропоновано багатofакторну модель ПЕН з використанням таких вхідних змінних: чисельність населення, обсягів імпорту та експорту, валового внутрішнього продукту на душу населення (ВВП) та валового національного доходу на душу населення (ВНД) для Індії. Чотири різні моделі сформовані для різних комбінацій вищезгаданих п'яти вхідних змінних, також продемонстровано вплив вхідних змінних на оцінку попиту на електроенергію. Для навчання мережі використані дані за 29 років, для тестування мережі — за 9 років. Було передбачено майбутній попит на електроенергію протягом 8 років — з 2013 по 2020 рік. Застосування техніки ANFIS виявилось кращим з MAPE=0,92%, ніж множинна лінійна регресія (MLR) та штучна нейронна мережа (ANN).

У праці (Masum, Liu & Chiverton, 2018) представлені результати багатоетапного прогнозування часових рядів, яке виконано на трьох наборах даних нелінійних електричних навантажень, для Великої Британії (GB), Польщі (PL) та Італії (IT). Набори складаються з даних про електричне навантаження з 01.02.2010 по

31.01.2014. В цьому дослідженні порівнюються моделі ARIMA та довготривалої короткочасної пам'яті (LSTM) на основі рекурентної нейронної моделі мережі (RNN). Порівняльний аналіз прогнозування на 10 кроків вперед трьох моделей показує, що модель LSTM має кращу продуктивність RMSE: для GB, PL, IT, відповідно, 3765, 1922 та 4876, порівняно з моделлю ARIMA для багатокрокового прогнозування електричного навантаження 4587, 2461 та 6263.

Виконаний аналіз літературних джерел показав, що найбільш перспективними методами багатокрокового ПЕН, які забезпечують найбільшу точність прогнозування, є ARIMA та ANFIS, тому ці методи ПЕН були вибрані для подальших досліджень. Для порівняння методів використані методи ANFIS та ARIMA і наївний прогноз.

**Мета статті:** дослідження методів короткострокового багатокрокового ПЕН промислових і цивільних об'єктів для забезпечення задач керування електроспоживанням та електропостачанням цих об'єктів.

**Матеріали і методи.** Для порівняння методів багатокрокового короткострокового ПЕН було вибрано об'єкт дослідження — промислове підприємство з виготовлення пластмасових виробів. Дослідження проводилися з використанням програмного забезпечення MATLAB 2020b і таких пакетів: Fuzzy Logic Toolbox та Econometrics Toolbox. Для прогнозування використано півгодинні щоденні виміри (48 вимірів на добу) навантаження (у МВт · год) з 01.04.2015 по 01.05.2015 з урахуванням святкових і вихідних днів.

При проведенні дослідження з використанням ANFIS було враховано екзогенний фактор: «час доби». Для порівняння досліджувалися такі методи прогнозування:

1. Статистичні методи: «наївний» прогноз і моделі часового ряду Бокса-Дженкінса (ARIMA).

2. Метод штучного інтелекту: ANFIS. У пропонованому дослідженні використовуємо три різні методи генерації системи нечіткого висновку (GENFIS): розбиття мережі (Grid Partitioning), метод субтрактивної кластеризації (Subtractive Clustering) та кластеризація нечітких С-середніх (FCM Clustering).

Варто звернути увагу на різницю між методами GENFIS. Так, метод Grid Partition передбачає, що простір вхідних даних поділяється на прямокутний підпростір за допомогою розділу, паралельного осі; кожен вхід розбивається на функції належності однакової форми. Кількість нечітких правил if-then дорівнює  $M^n$ , де  $n$  — вхідний розмір, а  $M$  — кількість розділених нечітких підмножин для кожної вхідної змінної (Benmouiza & Clustered, 2018).

Метод Subtractive Clustering (субтрактивна кластеризація) генерує точно налаштовані кластери для кожної вхідної змінної. Для кожного кластера вхідних змінних створюється правило. Алгоритм субтрактивної кластеризації розглядає кожну точку даних для кандидата на центр кластера (Maddipati, Pradeepini & Yesubabu, 2018).

Метод кластеризації нечітких С-середніх — FCM Clustering (FCM), заснований на нечіткому наборі шляхом вдосконалення методу кластеризації С-середніх. Метод кластеризації FCM — це метод поділу розділеної конкретної області шляхом перерахування значень, що належать до даних кластера, відповідно до ступеня належності кожного елемента даних, що належить одному кластеру (Yeom & Kwak, 2018).

Метод оцінки результатів прогнозування. У цьому дослідженні для перевірки точності прогнозування використовуємо RMSE та MAPE (Aras, Kocakoc & Polat, 2017), які визначаються таким чином:

$$RMSE = \sqrt{\sum_{t=1}^n \frac{(\hat{y}_t - y_t)^2}{n}}; \quad (1)$$

$$MAPE = \frac{100\%}{n} \sum_{t=1}^n \left| \frac{y_t - \hat{y}_t}{y_t} \right|, \quad (2)$$

де  $y_t$  — значення спостереження в момент часу  $t$ ;  $\hat{y}_t$  — прогнозоване значення в момент часу  $t$ ;  $n$  — кількість точок даних у наборі.

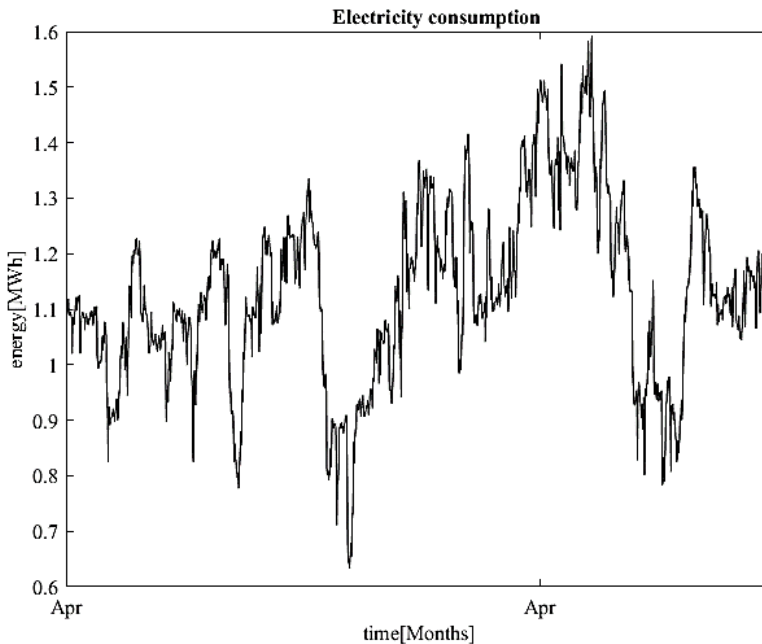
**Викладення основних результатів досліджень.** У цьому розділі статті представлена поетапна побудова моделей багатокрокового короткострокового ПЕН для статистичних методів (ARIMA, «найвний» прогноз) та інтелектуальної системи керування (ANFIS) за допомогою MATLAB 2020b.

*ПЕН за допомогою моделі ARIMA.*

Процес моделювання ARIMA з використанням моделі Бокса-Дженкінса передбачає дев'ять етапів:

Етап 1. Завантаження даних. Аналіз динаміки часового ряду.

Нижче графічно представлена динаміка споживання промислового підприємства з виготовлення пластмасових виробів за період з 01.04.2015 по 01.05.2015 (рис. 1).



**Рис. 1. Електричне навантаження промислового підприємства з 01.04.2015 по 01.05.2015**

Етап 2. Визначення потенційних моделей, шляхом розгляду вибіркової автокореляційної (ACF) та частково автокореляційної (PACF) функцій для вимірюваних даних (рис. 2, 3).

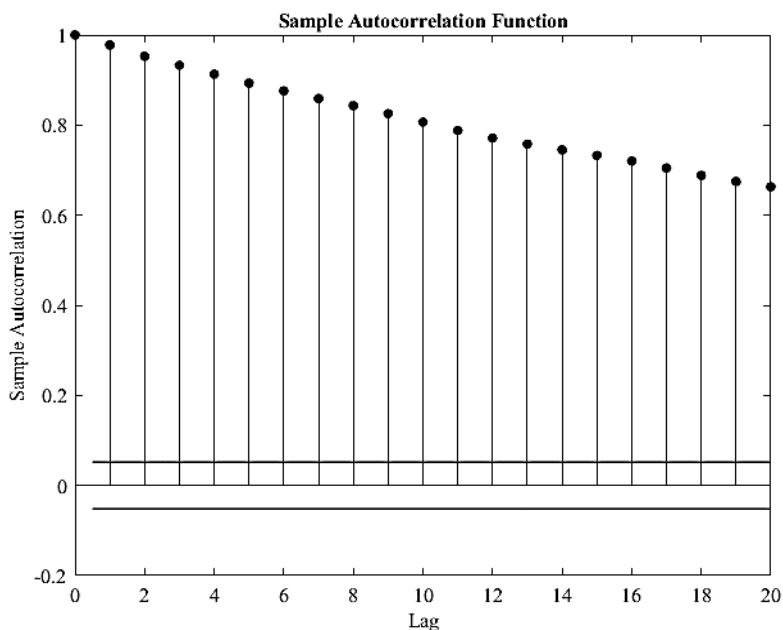


Рис. 2. Моделювання вибіркової автокореляції (ACF) даних

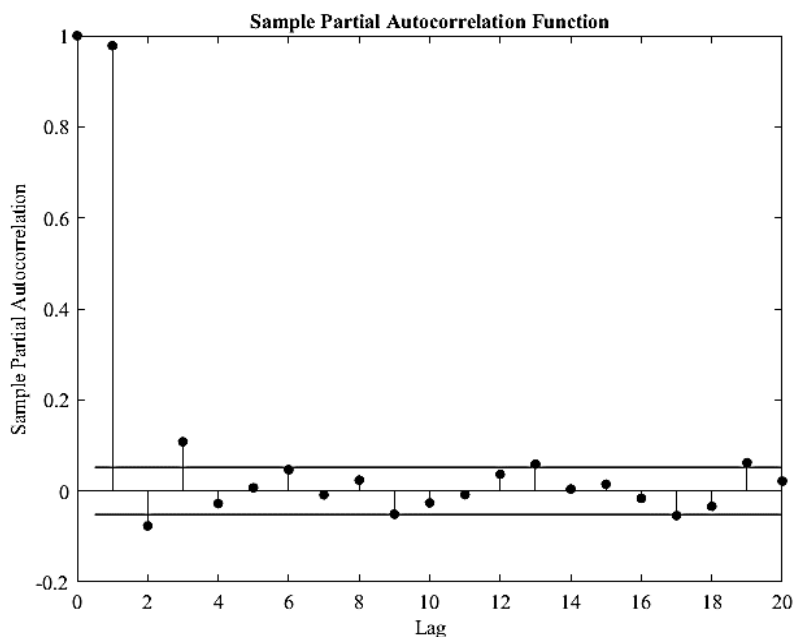
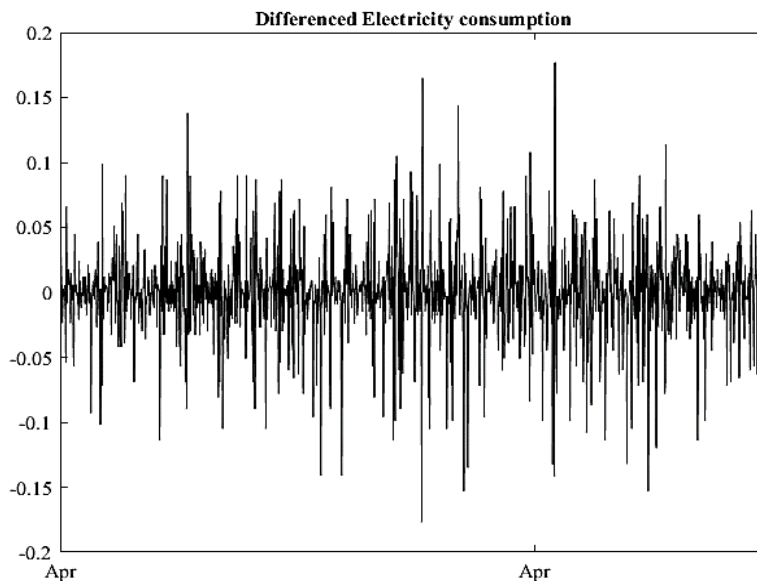


Рис. 3. Моделювання вибіркової часткової автокореляції (PACF) даних



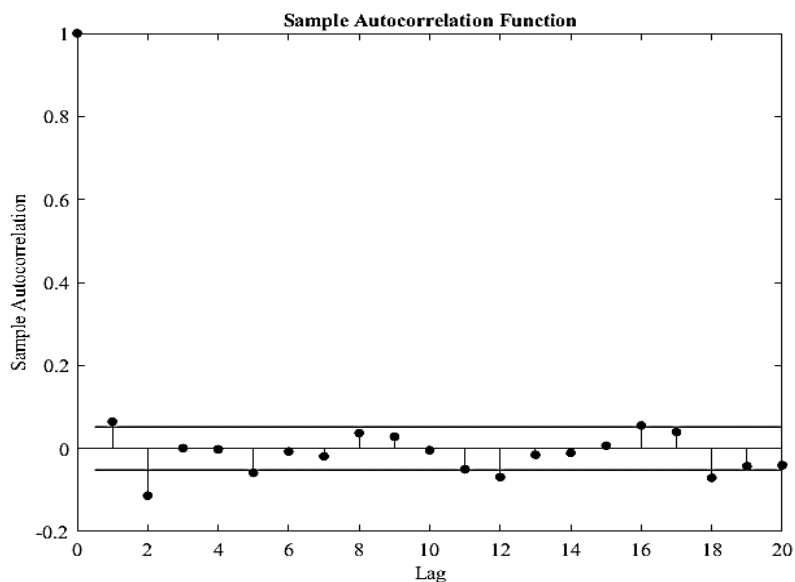
Наявність значного лінійного спадання функції ACF, згідно з рис. 2, вказує на нестационарний процес.

Етап 3. Перехід до різниці даних і побудова різницевого ряду (рис. 4).



**Рис. 4. Графік різницевого ряду**

Етап 4. Визначення потенційних моделей шляхом розгляду виду ACF та PACF до різниці даних.



**Рис. 5. Автокореляційна функція (ACF) до різниці даних**

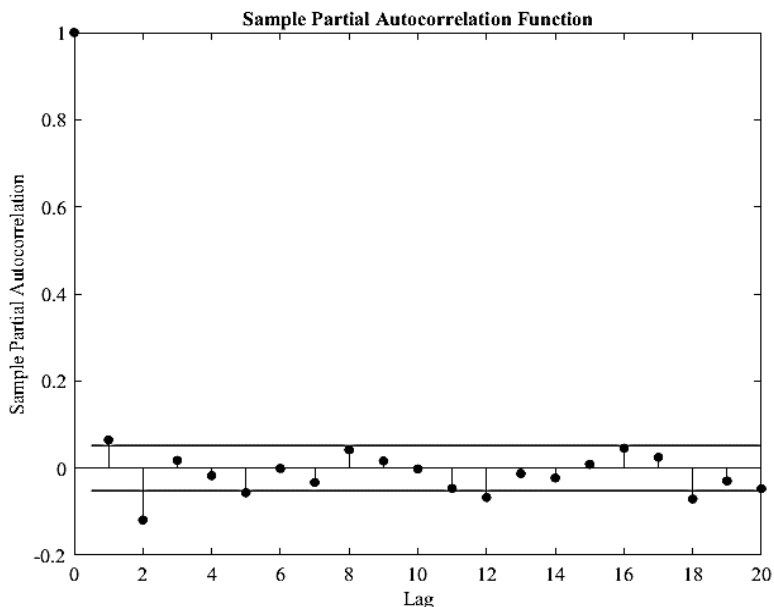


Рис. 6. Часткова автокореляційна функція (PACF) до різниці даних

Вибіркові ACF та PACF, наведені на рис. 5 і 6, відсікаються після двох кроків.

Етап 5. Визначення кількості разів диференціювання, тобто параметра  $D$  в моделі ARIMA ( $p, D, q$ ) за стаціонарністю різниць даних певного порядку. Визначаємо стаціонарність різниці першого порядку на основі розширеного тесту Дікі-Фуллера:  $h1 = adfstest(y)$ ;  $h = adfstest(dY)$ .

Якщо  $h1 = 0$ , а  $h = 1$ , тоді перша різниця даних є стаціонарною, тобто параметр  $D$  дорівнює 1.

Етап 6. Вибір найкращої моделі ARIMA ( $p, D, q$ ).

На цьому етапі вибираємо найкращу модель, використовуючи критерій AIC та BIC.

Для цього вибираємо параметри:  $\max\_p = 5$ ;  $\max\_q = 5$ .

Проведене моделювання дало змогу встановити, що найкращою моделлю є ARIMA (4, 1, 2). Після вибору найкращої моделі ARIMA дані вимірювань розділяють на навчальну і тестову вибірку. Навчальна вибірка була сформована для даних з 01.04.2015 по 30.04.2015, а тестова — для 01.05.2015. Модель ARIMA навчається на першій вибірці:

Model = ARIMA (4, 1, 2);

EstMdl = estimate(Model, X\_train).

У результаті навчання моделі визначаємо параметри, які наведено в табл. 1.

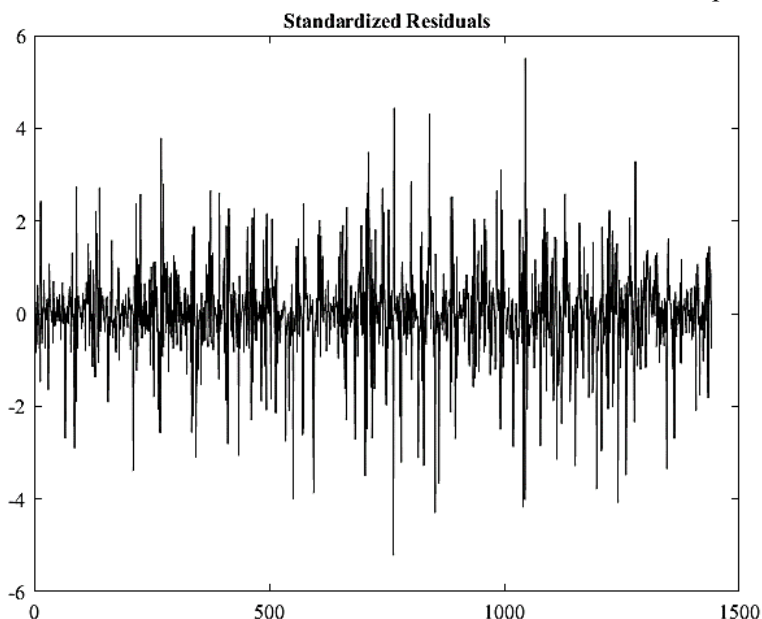
Моделі ARIMA (4, 1, 2) відповідає таке рівняння:

$$(1 - \phi_1 L - \phi_2 L^2 - \phi_3 L^3 - \phi_4 L^4)(1 - L)y_t = c + (1 + \theta_1 L + \theta_2 L^2)\varepsilon_t. \quad (3)$$

*Таблиця 1. Оцінка параметрів і діагностична перевірка методу ARIMA (4,1,2)*

Параметри	Value	Standard Error	TStatistic	PValue
Constant	-2.3021e-05	0.00071349	0.032266	0.97426
AR{1}	1.1898	0.052726	22.565	9.5034e-113
AR{2}	-1.0765	0.056215	-19.149	9.8604e-82
AR{3}	0.2248	0.032947	6.8232	8.9065e-12
AR{4}	-0.15608	0.022079	-7.0691	1.5593e-12
MA{1}	-1.1244	0.052197	-21.542	6.2679e-103
MA{2}	0.88615	0.047773	18.549	8.2669e-77
Variance	0.0011643	2.6515e-05	43.91	0

Етап 7. Перевірка адекватності встановленої моделі ARIMA (4,1,2), ACF та PACF за властивостями залишків моделі відносно навчальної вибірки.



**Рис. 7. Ділянка стандартизованих залишків моделі ARIMA (4,1,2)**

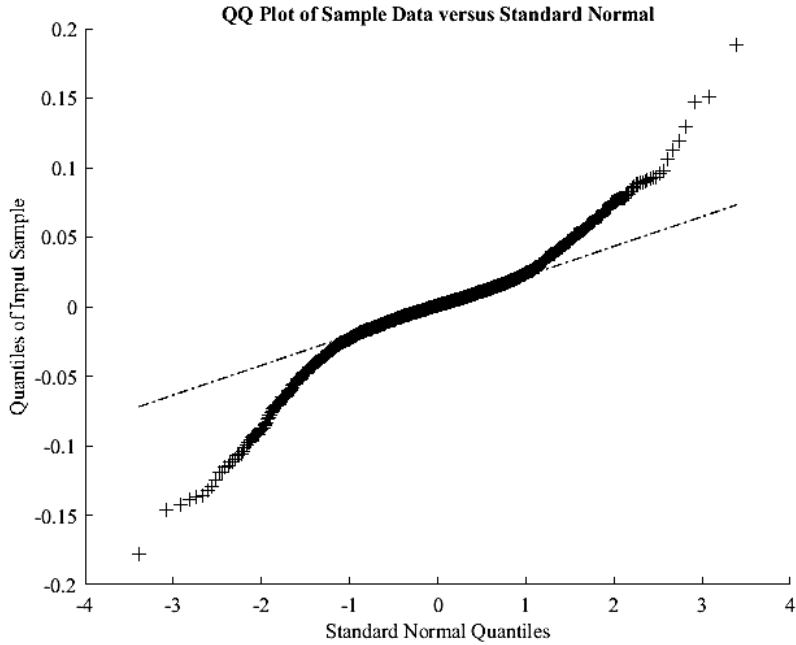


Рис. 8. Q-Q графік для визначення нормальності розподілу залишків моделі ARIMA (4,1,2)

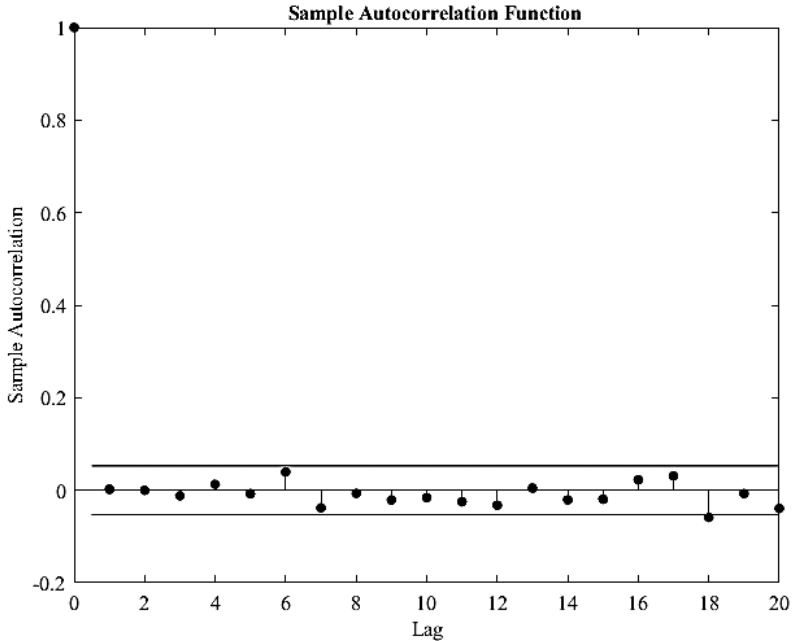


Рис. 9. Графік автокореляції (ACF) залишків моделі ARIMA (4,1,2)

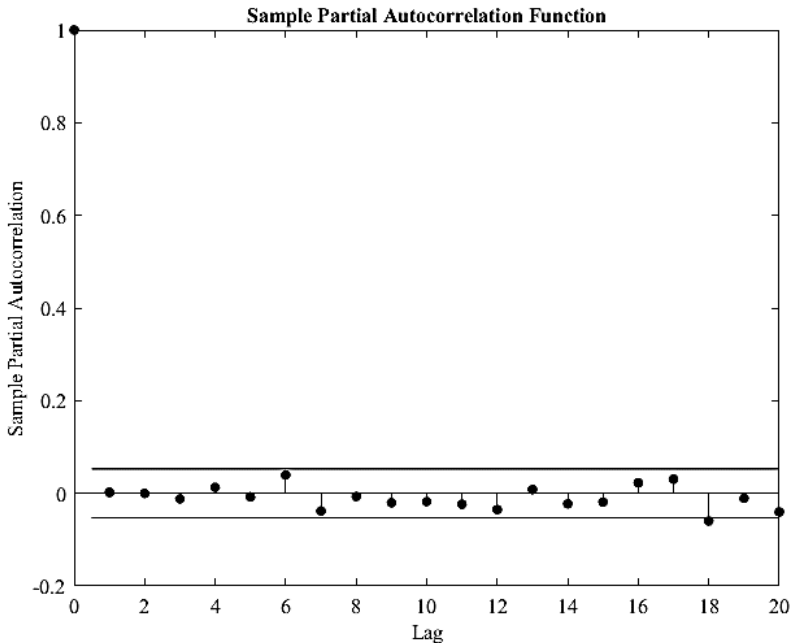


Рис. 10. Графік часткової автокореляції (PACF) залишків моделі ARIMA (4,1,2)

Як видно з рис. 7, 8, 9, 10, залишки нормально розподілені та некорельовані, тому модель адекватна для цієї вибірки.

Етап 8. Прогнозування результатів на основі даних. Окремо робиться прогноз для навчальної і тестової вибірки.

Для навчальної вибірки багатокрокове прогнозування проводиться за таким алгоритмом:

```

for i = 1:30
    x_for = EndTrainData-48*i+1:EndTrainData-48*(i-1);
    [YTrain1_for, YMSEf] = forecast(EstMdl, 48, X_train(1:EndTrainData-47*i));
    RMSEYTrain1_for(i) = sqrt(mean((YTrain1_for-X_train(x_for)).^2));
    lower1 = YTrain1_for + 1.96*sqrt(YMSEf);
    upper1 = YTrain1_for - 1.96*sqrt(YMSEf);
    plot(x_for, YTrain1_for, 'r', 'LineWidth', 2);
    plot(x_for, lower1, 'k--', 'LineWidth', 2);
    plot(x_for, upper1, 'k--', 'LineWidth', 2);
    % збираємо всі 48-точкові масиви в один
    YTrain1_for_all(x_for, 1) = YTrain1_for(:, 1);
end.
    
```

Виконання багатокрокового прогнозування для тестової вибірки проводиться за таким алгоритмом:

```

step=48;
x_for = EndTrainData+1:EndTrainData+step;
[yF1, YMSEf] = forecast(EstMdl, step, X_train)
    
```

Етап 9. Визначення похибок RMSE та MAPE для навчальної та тестової вибірки.

```
RMSETrain1 = sqrt(mean((X_train-YTrain1_for_all).^2))
mapeTrain1 = mean(abs((X_train - YTrain1_for_all)./X_train))
RMSEYTest1 = sqrt(mean((YTest1'-X_test).^2))
mapetest1 = mean(abs((X_test - yF1)./X_test)).
```

*Таблиця 2. Результати прогнозування встановленої моделі ARIMA (4,1,2)*

Модель ARIMA	RMSE		MAPE	
	Train	Test	Train	Test
ARIMA(4,1,2)	0,1216	0,052	0,077	0,035

*ПЕН за допомогою «найвного» прогнозу.*

Процес моделювання за «найвним» прогнозом передбачає чотири етапи:

Етап 1. Завантаження даних:

```
y = Data(:,2);
T = length(y).
```

Етап 2. Розділення даних на навчальну і тестову вибірку. Навчальну вибірку розділяємо для даних з 01.04.2015 по 30.04.2015, а тестову — для даних на 01.05.2015.

Етап 3. «Наївне» прогнозування для навчальної та тестової вибірки даних. Для навчальної вибірки даних використовуємо алгоритм і нульову модель ARIMA (0,0,0):

```
Md1 = arima(0,0,0);
EstMod = estimate(Md1, y(EndTrainData));
YTrain48(1:3)=X_train(1:3);
figure
h8 = plot(y,'Color',[.5,.5,.5]);
hold on
dateStart48 = datestr(now, 'dd-mm-yyyy MM:ss')
for i = 1:30
x_for = EndTrainData-48*i+1:EndTrainData-48*(i-1);
[YTrain1_for, YMSEf] = forecast(EstMod, 48, y(EndTrainData-47*i+1));
RMSEYTrain1_for(i) = sqrt(mean((YTrain1_for-X_train(x_for)).^2));
lower1 = YTrain1_for - 1.96*sqrt(YMSEf);
upper1 = YTrain1_for + 1.96*sqrt(YMSEf);
plot(x_for, YTrain1_for, 'r', 'LineWidth', 2);
plot(x_for, lower1, 'k--', 'LineWidth', 2);
plot(x_for, upper1, 'k--', 'LineWidth', 2);
YTrain1_for_all(x_for, 1) = YTrain1_for(:, 1);
end
dateEnd48 = datestr(now, 'dd-mm-yyyy MM:ss').
```

Для тестових даних необхідно використовувати нульову модель ARIMA (0,0,0). Для тестової вибірки даних використовуємо алгоритм:

```
Md1 = arima(0,0,0);
EstMod = estimate(Md1, y(EndTrainData));
```

$Y_{for1} = \text{forecast}(\text{EstMod}, \text{LenForecast}, y(\text{XTest}))$ .

Етап 4. Визначення похибок RMSE та MAPE для навчальної та тестової вибірки.

$\text{RMSE}_{\text{train}} = \sqrt{\text{mean}((y(\text{XTrain}) - Y_{for})^2)}$ ;

$\text{mape}_{\text{Train1}} = \text{mean}(\text{abs}((X_{\text{train}} - Y_{\text{Train1\_for\_all}}) / X_{\text{train}}))$

$\text{RMSE}_{\text{Test}} = \sqrt{\text{mean}((y(\text{XTest}) - Y_{for1})^2)}$

$\text{mape}_{\text{Train1}} = \text{mean}(\text{abs}((y(\text{XTest}) - Y_{for1}) / (y(\text{XTest}))))$ .

Таблиця 3. Результати прогнозування встановленої моделі «наївного» прогнозу

Модель	RMSE		MAPE	
	Train	Test	Train	Test
«Наївний» прогноз	0,173	0,0597	0,1329	0,0418

*ПЕН за допомогою ANFIS.*

Процес моделювання ANFIS передбачає шість етапів:

Етап 1. Обробка вхідних даних. Модель має сім входів:

- година дня;
- навантаження попереднього дня, тобто на один крок назад ( $t-1$ );
- навантаження попереднього дня, тобто на два кроки назад ( $t-2$ );
- навантаження попереднього дня, тобто на три кроки назад ( $t-3$ );
- навантаження попереднього дня, тобто на чотири кроки назад ( $t-4$ );
- навантаження попереднього дня, тобто на п'ять кроки назад ( $t-5$ );
- навантаження попереднього дня, тобто на шість кроків назад ( $t-6$ ).

Вихідними даними моделі є дані електричного навантаження з 01 квітня по 01 травня 2015 року. На рис. 11. показана блок-схема, де зазначено входи та виходи мережі ANFIS.

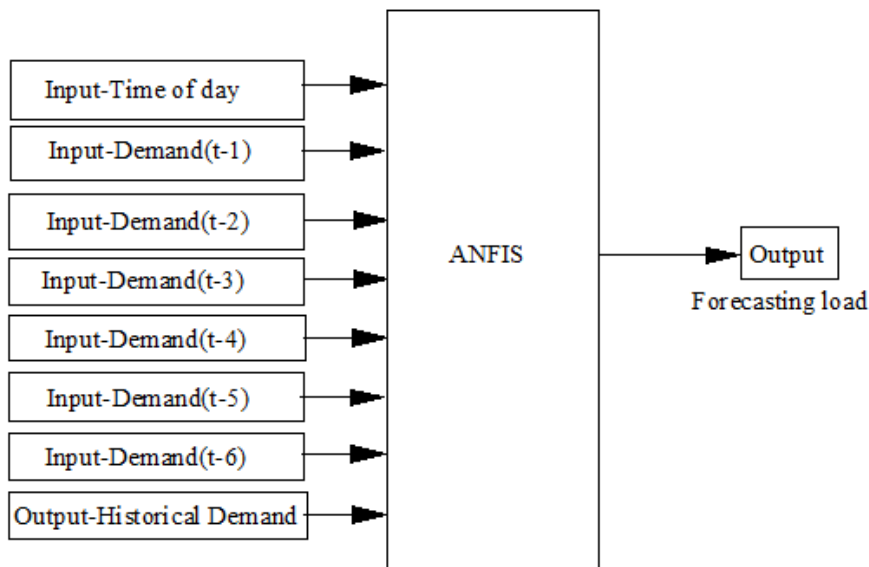


Рис. 11. Блок-схема з вхідними та вихідними даними для ANFIS

Алгоритм виконання.

timeDay = Data(:,1)

Demand6 = Data(:,2)

Demand5 = Data(:,3)

Demand4 = Data(:,4)

Demand3 = Data(:,5)

Demand2 = Data(:,6)

Demand1 = Data(:,7)

Inputs = [timeDay Demand6 Demand5 Demand4 Demand3 Demand2 Demand1]

Outputs = Data(:,8)

data = [Inputs Outputs].

Навчальні дані представлені у вигляді матриці 1488 x 8.

Етап 2. Розділення даних на навчальну і тестову вибірку. Дані навчальної вибірки з 01 квітня по 30 квітня 2015 року представляються у формі матриці 1440x8, а дані для тестування на 01 травня 2015 року — у формі матриці 48x8.

Етап 3. Встановлення параметрів методів FIS для навчальних даних. На цьому етапі використовуються моделі ANFIS: Grid Partitioning, Subtractive Clustering, FCM Clustering, які розраховують окремо для цього етапу (табл. 4).

*Таблиця 4. Вхідні параметри функцій genfis*

Модель genfis	Вхідні параметри
Grid partitioning opt1= genfisOptions('GridPartition')	NumMembershipFunctions = [2]; InputMembershipFunctionType = ["trimf"] OutputMembershipFunctionType= ["linear"]
Subtractive Clustering opt1 = genfisOptions('SubtractiveClustering')	ClusterInfluenceRange = 0.38; DataScale = 'auto'; SquashFactor = 1.25; AcceptRatio = 0.3; RejectRatio = 0.15; Verbose = true
FCM Clustering opt1=genfisOptions('FCMClustering','FISType','sugeno');	NumClusters = 65; Exponent = 3.0; MaxNumIteration = 100; MinImprovement = 1e-5; Verbose = true

Створення системи нечітких висновків (FIS). За замовчуванням структура FIS створюється з використанням розділу мережі вхідних і вихідних змінних, з використанням функції genfis:

fis1 = genfis(TrainInputs,TrainOutputs,opt1).

Етап 4. Структура навчання ANFIS. На цьому етапі навчаємо через 100 епох нашу модель fis, для моделей *Subtractive Clustering* та *FCM Clustering* вибираємо метод Backpropagation ANFIS, тобто OptimizationMethod=0, тоді для *Grid partitioning* вибираємо гібридний метод ANFIS, тобто в нашому випадку OptimizationMethod=1.

fis=anfis([TrainInputs TrainOutputs],...



fis1,TrainOptions,DisplayOptions,[],OptimizationMethod).

Етап 5. Прогнозування ПЕН FIS за використанням функції evalfis:

TrainForecast=evalfis(fis,TrainInputs)

TestForecast=evalfis(fis,TestInputs).

Етап 6. Визначення похибки RMSE для навчальної та тестової вибірки:

RMSEYTrain1 = sqrt(mean((TrainOutputs-TrainForecast).^2))

mapeTrain1=mean(abs((TrainOutputs-TrainForecast)./TrainOutputs))

RMSEYTest1 = sqrt(mean((TestOutputs-TestForecast).^2))

mapeTest1 = mean(abs((TestOutputs-TestForecast)./TestOutputs)).

*Таблиця 5. Результати прогнозування встановленої моделі ANFIS*

Модель ANFIS	Вхідні параметри	RMSE		MAPE	
		Train	Test	Train	Test
Grid partitioning	Кількість термів — 2; Функція належності — 'trimf' Тип функції вихідного членства — 'linear'	0,0269	0,3054	0,0175	0,206
Subtractive Clustering	Діапазон впливу кластера — 0,38	0,04	0,1108	0,026	0,078
FCM Clustering	Кількість кластерів — 65	0,0929	0,1153	0,0638	0,092

Порівняння результатів ПЕН виконаємо на основі консолідованих даних табл. 6.

*Таблиця 6. Результати прогнозування для всіх методів прогнозування*

Метод ПЕН	Похибка RMSE		Похибка MAPE	
	Train	Test	Train	Test
ARIMA(4,1,2)	0,1216	0,052	0,077	0,035
Наївний прогноз	0,173	0,0597	0,1329	0,0418
Grid partitioning з 2 термами	0,0269	0,3054	0,0175	0,206
Subtractive Clustering	0,04	0,1108	0,026	0,078
FCM Clustering	0,0929	0,1153	0,0638	0,092

З даних, наведених у табл. 6, видно, що для багатокрокового прогнозування для тестової вибірки більш точний прогноз дає модель ARIMA(4,1,2), а моделі ANFIS та «наївного прогнозу» є менш точними.

### **Висновки**

На основі проведених розрахункових досліджень методів короткострокового ПЕН з використанням двох моделей на основі статистичних методів і трьох моделей на основі ANFIS встановлено, що найбільш ефективною є модель прогнозування ARIMA(4,1,2). RMSE для тестової вибірки становить 0,052, а похибка MAPE тестової вибірки становить 0,035.

Дослідження показало доцільність застосування моделей ANFIS, «наївного» прогнозу та ARIMA для короткострокового багатокрокового ПЕН забезпечення ефективного функціонування систем керування електроспоживанням та електропостачанням промислових підприємств і цивільних об'єктів.

У подальших дослідженнях планується розробка моделей прогнозування вироблення електроенергії для фотоелектростанцій на основі моделей штучного інтелекту.

### Література

An, N., Anh, D. T. (2015). Comparison of Strategies for Multi-step-Ahead Prediction of Time Series Using Neural Network. *2015 International Conference on Advanced Computing and Applications (ACOMP)*, 142—149. <https://doi.org/10.1109/ACOMP.2015.24>.

Aras, S., Kocakoc, I. D., Polat, C. (2017). Comparative study on retail sales forecasting between single and combination methods. *Journal of Business Economics and Management*, 18(5), 803—832. <https://doi.org/10.3846/16111699.2017.1367324>.

Benmouiza, K., Clusered, A. C. (2018) ANFIS network using fuzzy c-means, subtractive clustering, and grid partitioning for hourly solar radiation forecasting. *Theoretical and Applied Climatology*, 137(1—2), 31—43. DOI:10.1007/s00704-018-2576-4.

Jain, P., Quamer, W. Pamula, R. (2018). Electricity Consumption Forecasting Using Time Series Analysis: Second International Conference, *ICACDS 2018*, 20—21. DOI:10.1007/978-981-13-1813-9\_33.

Maddipati, S. S., Pradeepini, D. G., Yesubabu, D. A. (2018). Software Defect Prediction using Adaptive Neuro Fuzzy Inference System. *International Journal of Applied Engineering Research*, 13(1), 394—397.

Masum, S., Ying, L., Chiverton, J. (2018). Multi-step Time Series Forecasting of Electric Load Using Machine Learning Models. *7th International Conference on Artificial Intelligence and Soft Computing: ICAISC 2018*, 148—159. DOI:10.1007/978-3-319-91253-0\_15.

Saravanan, S., Kannan, S., Thangaraj, C. (2015). Prediction of India's Industrial Sector Electricity Consumption Using ANFIS. *In Power Electronics and Renewable Energy Systems*, 5(3), 985—990. DOI: 10.21917/ijsc.2015.0138.

Shao, X., Kim, C. S. (2020). Multi-Step Short-Term Power Consumption Forecasting Using Multi-Channel LSTM With Time Location Considering Customer Behavior. *IEEE Access*, 8, 125263—125273. DOI:10.1109/ACCESS.2020.3007163.

Taieb, B. S., Bontempi, G., Atiya, A., Sorjamaa, A. (2012). A review and comparison of strategies for multi-step ahead time series forecasting based on the NN5 forecasting competition. *Expert Systems with Applications: An International Journal Volume*, 39(8), 7067—7083. <https://doi.org/10.1016/j.eswa.2012.01.039>.

Tay, K. G., Muwafaq, H., Tiong, W. K., Choy, Y. Y. (2019). Electricity Consumption Forecasting Using Adaptive Neuro-Fuzzy Inference System (ANFIS). *Universal Journal of Electrical and Electronic Engineering*, 6(5B), 37—48. DOI:10.13189/ujeee.2019.061606.

Yeom, C. U., Kwak, K. C. (2018). Performance Comparison of ANFIS Models by Input Space Partitioning Methods. *Symmetry. 2018 IEEE 9th Annual Information Technology, Electronics and Mobile Communication Conference (IEMCON)*, 10(12), 1—25. DOI:10.3390/sym10120700.