

Національний технічний університет України
«Київський політехнічний інститут імені Ігоря Сікорського»
Міністерство освіти і науки України
Національний технічний університет України
«Київський політехнічний інститут імені Ігоря Сікорського»
Міністерство освіти і науки України

Кваліфікаційна наукова
праця на правах рукопису

КОЛОМОЄЦЬ СЕРГІЙ ОЛЕКСІЙОВИЧ

УДК 004; 004.8

ДИСЕРТАЦІЯ
МЕТОДИ ІНТЕЛЕКТУАЛЬНОГО ПРОГНОЗУВАННЯ
АРТЕРІАЛЬНОГО ТИСКУ ТА КЛАСИФІКАЦІЇ АРТЕРІАЛЬНОЇ
ГІПЕРТЕНЗІЇ

126 Інформаційні системи та технології

12 Інформаційні технології

Подається на здобуття наукового ступеня доктора філософії

Дисертація містить результати власних досліджень. Використання ідей, результатів і текстів інших авторів мають посилання на відповідне джерело _____ С.О. Коломоєць

Науковий керівник Чумаченко Олена Іллівна, д.т.н., професор

Київ – 2025

АНОТАЦІЯ

Коломоець С.О. Методи інтелектуального прогнозування артеріального тиску та класифікації артеріальної гіпертензії. – Кваліфікаційна наукова праця на правах рукопису.

Дисертація на здобуття наукового ступеня доктора філософії за спеціальністю 126 – Інформаційні системи та технології в галузі знань 12 – Інформаційні технології. – Національний технічний університет України «Київський політехнічний інститут імені Ігоря Сікорського», Київ, 2025.

Дисертаційну роботу присвячено розробці методів обробки сигналів безманжетного вимірювання артеріального тиску з подальшим їх прогнозуванням та розробці інтелектуальних методів класифікації ступеня артеріальної гіпертензії на основі використання гібридних нейронних мереж ансамблевого типу.

В роботі проведено аналіз існуючих проблем з захворюваннями серцево-судинної системи, а саме проблеми діагностування артеріальної гіпертензії, яка характеризується підвищеним артеріальним тиском, що може привести до виникнення таких тяжких захворювань як інфаркт або інсульт.

Показано, що основним шляхом запобігання таких хвороб є постійний моніторинг артеріального тиску завдяки використанню безманжетного вимірювання артеріального тиску з подальшим його прогнозуванням за часом, що може надати можливість термінового інформування хворих та лікарів про необхідність медикаментозного втручання, що дозволить в короткий термін знизити артеріальний тиск. Другим шляхом запобігання вищезазваних вражаючих ефектів є розробка інтелектуальної системи діагностування ступеню артеріальної гіпертензії.

У першому розділі наведено інформаційну довідку щодо поширення АГ у світі, зокрема в Україні і зроблено висновок, що стан цієї проблеми не відповідає світовим стандартам, зокрема європейським. Особливо це стосується практичній відсутності використання безманжетного вимірювання

тиску для загальної спільноти. Проведено аналіз існуючих приладів по безманжетному вимірюванню тиску.

У другому розділі обґрунтовано використання методів прогнозування часових рядів до прогнозу артеріального тиску у хворих. Наведено новий метод прогнозування артеріального тиску, який полягає у використанні методів попередньої обробки результатів вимірювання та методів прогнозування часових рядів.

Виконано огляд наукових робіт з попередньої обробки даних. Обґрунтовано використання методів усунення шумів, виявлення та усунення аномалій, заповнення відсутніх даних за якими наведено результати попередньої обробки. В якості експериментальних даних для обробки було взято дані надані Державною установою «Національний науковий центр ім. акад. М.Д. Стражеска». Проведено аналіз відомих методів прогнозування часових рядів для даних вимірювання артеріального тиску. Показано, що найкращі результати дають методи на основі використання рекурентних нейронних мереж, а саме LSTM, GRU, BI-LSTM. З метою покращення результатів прогнозування запропоновано використання нового підходу, який передбачає застосування гібридних нейронних мереж на основі бустингу, а саме послідовного з'єднання таких нейронних мереж як LSTM, GRU та низки їх комбінацій. Отримані результати показали ефективність запропонованого підходу, а саме вдалося підвищити точність прогнозування різних горизонтів в середньому на 10%.

В третьому розділі вирішена задача по вибору суттєвих ознак які характеризують ступінь артеріальної гіпертензії, а саме:

- для першого ступеню значеннями тиску;
- для другого ступеню значеннями тиску аналізами крові та сечі (еритроцити, лейкоцити, гемоглобін, тромбоцити, рівень білка, рівень креатиніну, рівень холестерину (загального), рівень цукру (глюкоза), калій, магній, натрій, адреналін, норадреналін, альдостерон), аномальними показниками, які можна виявити на ЕКГ та ЕхоКГ (індекс Соколова — Лайона,

вольтажний індекс Корнелла, ІМЛШ, хронічною хворобою нирок третьої стадії, кісточно-плечовим індексом, важкою ретинопатією;

– для третього ступеню значеннями тиску, наявністю аномальних значень в аналізах, ЕКГ та ЕхоКГ як при II ступені артеріальної гіпертензії, наявністю в анамнезі цереброваскулярних захворювань (внутрішньомозкового крововиливу, ішемічного інсульту, транзиторної ішемічної атаки), наявністю в анамнезі ішемічної хвороби серця (інфаркта міокарда, реваскуляризації міокарда, стенокардії), виявленню стенозу під час візуалізаційних досліджень, наявності тяжкої альбумінурії, наявністю четвертої або п'ятої стадії хронічної хвороби нирок.

Обґрунтовано необхідність використання гібридних нейронних мереж побудованих на основі ансамблевого підходу для розв'язання задачі класифікації ступенів АГ. На основі проведеного аналізу показано що найкращим варіантом є використання бегінгу при цьому розроблено новий метод для розв'язання даної задачі. Отримані результати показали ефективність запропонованого методу.

В четвертому розділі розроблено інформаційні технології та сценарії використання запропонованої інформаційної технології щодо інтелектуального прогнозування АТ.

Результати, отримані в дисертаційному дослідженні, містять наукову новизну:

– вперше запропоновано метод для обробки даних артеріального тиску у хворих, який відрізняється тим, що на основі методів безманжетного вимірювання здійснює попередню обробку отриманих даних та подальше прогнозування на основі використання гібридних рекурентних нейронних мереж, горизонт прогнозу яких адаптовано під поточний стан пацієнта, що дає можливість знизити імовірність виникнення інсульту або інфаркту у хворих;

– удосконалено метод вирішення задачі класифікації та знижено обчислювальні витрати при машинному навчанні гібридних нейронних мереж за рахунок визначення найбільш впливових ознак артеріальної гіпертензії для

різних ступенів захворювання, які крім загальних ознак (анамнез, результати огляду лікаря, результати аналізів крові, сечі, вимірювання артеріального тиску) включають результати обробки ЕКГ, ЕхоКГ;

– розроблено метод структурно-параметричного синтезу гібридної нейронної мережі для розв’язання задачі класифікації ступеня артеріальної гіпертензії, який відрізняється тим, що гібридна нейронна мережа будується на основі створення беггінг-ансамблю інтелектуальних класифікаторів, включених в ансамбль за критеріями точності та різноманіття, що дозволяє підвищити точність класифікації.

Дисертаційна робота складається зі вступу, 4 розділів, висновків, списку використаних джерел з 210 найменувань та одного додатку. Загальний обсяг дисертації складає 150 сторінок, містить 47 рисунків та 21 таблицю.

Ключові слова: артеріальна гіпертензія, глибоке навчання, інформаційна технологія, класифікація, машинне навчання, нейронна мережа, оптимізація, прогнозування, штучний інтелект, штучна нейронна мережа.

ABSTRACT

Kolomoiets S.O. Methods of intellectual prediction of blood pressure and classification of arterial hypertension.

Dissertation for the degree of Doctor of Philosophy in the specialty 126 – Information systems and technologies in the field of knowledge 12 – Information technology – National Technical University of Ukraine “Igor Sikorsky Kyiv Polytechnic Institute”, Kyiv, 2025.

The dissertation is devoted to the development of methods for processing signals of cuffless blood pressure measurement with their subsequent prediction and the development of intelligent methods for classifying the degree of hypertension based on the use of hybrid ensemble-type neural networks.

The paper analyzes the existing problems with diseases of the cardiovascular system, namely the problem of diagnosing arterial hypertension, which is characterized by high blood pressure, which can lead to serious diseases such as heart attack or stroke.

It has been shown that the main way to prevent such diseases is to constantly monitor blood pressure through the use of cuffless blood pressure measurement with its subsequent time prediction, which can provide an opportunity to urgently inform patients and doctors about the need for medical intervention, which will allow to reduce blood pressure in a short time. The second way to prevent the aforementioned striking effects is to develop an intelligent system for diagnosing the degree of hypertension.

The first section provides information on the prevalence of hypertension in the world, including Ukraine, and concludes that the state of this problem does not meet international standards, including European ones. This is especially true for the practical absence of cuffless blood pressure measurement for the general public. An analysis of existing cuffless pressure measurement devices is carried out.

The second section substantiates the use of time series forecasting methods for predicting blood pressure in patients. A new method of blood pressure prediction

is presented, which consists in the use of methods of preliminary processing of measurement results and methods of time series prediction.

A review of scientific works on data preprocessing is made. The use of methods for noise reduction, detection and elimination of anomalies, and filling in missing data for which the results of pre-processing are presented is substantiated. The data provided by the State Institution “National Scientific Center named after Academician M.D. Strazhesko” were used as experimental data for processing. We analyzed the known methods of time series prediction for blood pressure data. It is shown that the best results are obtained by methods based on the use of recurrent neural networks, namely LSTM, GRU, BI-LSTM. In order to improve the forecasting results, a new approach is proposed, which involves the use of hybrid neural networks based on boosting, namely the sequential connection of such neural networks as LSTM, GRU and a number of their combinations. The obtained results demonstrate the effectiveness of the proposed approach, namely, it was possible to increase the accuracy of forecasting different horizons by an average of 10%.

The third section solved the problem of selecting the essential features that characterize the degree of hypertension, namely:

- for the first degree, pressure values;
- for the second degree - pressure values by blood and urine tests (red blood cells, white blood cells, hemoglobin, platelets, protein level, creatinine level, cholesterol (total), sugar (glucose), potassium, magnesium, sodium, adrenaline, norepinephrine, aldosterone), abnormal values that can be detected on ECG and echocardiography (Sokolow-Lyon index, Cornell volt index, IML, chronic kidney disease of the third stage, ankle-brachial index, severe retinopathy;
- for the third degree, blood pressure values, abnormal values in the tests, ECG and echocardiogram as in the second degree of arterial hypertension, history of cerebrovascular diseases (intracerebral hemorrhage, ischemic stroke, transient ischemic attack), a history of coronary heart disease (myocardial infarction, myocardial revascularization, angina pectoris), detection of stenosis during imaging

studies, severe albuminuria, and the presence of stage four or five chronic kidney disease.

The necessity of using hybrid neural networks built on the basis of the ensemble approach to solve the problem of classifying the degrees of hypertension is substantiated. Based on the analysis, it is shown that the best option is to use backpropagation, and a new method for solving this problem is developed. The results obtained have shown the effectiveness of the proposed method.

In the fourth chapter, information technologies and scenarios for the use of the proposed information technology for the intelligent prediction of blood pressure are developed.

The results obtained in the dissertation study contain scientific novelty:

- For the first time, a method for processing blood pressure data in patients was proposed, which differs in that it uses cuffless measurement methods to pre-process the data and further forecasting based on the use of hybrid recurrent neural networks, the forecast horizon of which is adapted to the current state of the patient, which makes it possible to reduce the likelihood of stroke or heart attack in patients;
- improved method of solving the classification problem and reduced computational costs in machine learning of hybrid neural networks by identifying the most influential signs of hypertension for different degrees of the disease, which, in addition to general signs (anamnesis, results of medical examination, results of blood and urine tests, blood pressure measurements), include the results of ECG and echocardiography;
- a method of structural and parametric synthesis of a hybrid neural network for solving the problem of classifying the degree of hypertension, which differs in that the hybrid neural network is built on the basis of creating a bagging ensemble of intelligent classifiers included in the ensemble according to the criteria of accuracy and diversity, which allows to increase the accuracy of classification.

The thesis consists of an introduction, 4 chapters, conclusions, a list of 210 references and one appendix. The total volume of the dissertation is 150 pages, contains 47 figures and 21 tables.

Keywords: arterial hypertension, deep learning, information technology, classification, machine learning, neural network, optimization, prediction, artificial intelligence, artificial neural network.

Список публікацій здобувача

1. Chumachenko, O., & Kolomoiets, S. (2022). Using of artificial intelligence to solve the problem of cardiovascular disease diagnostics. *Electronics and Control Systems*, 2(72), 9–13. <https://doi.org/10.18372/1990-5548.72.16928>
2. Sineglazov, V., Chumachenko, O., & Kolomoiets, S. (2022). Determination of characteristics of infectious endocarditis based on intelligent processing of ultrasonic images. *Electronics and Control Systems*, 4(74), 18–26. <https://doi.org/10.18372/1990-5548.74.17292>.
3. Kolomoiets, S. (2024). Concepts of creating an intelligent medical diagnostic system to assist in the work and training of doctors based on artificial intelligence. *Information Technology and Society*, (5 (11)), 28–33. <https://doi.org/10.32689/maup.it.2023.5.4>.
4. Kolomoiets, S. O. (2024). Intelligent medical systems based on artificial intelligence. *Scientific Notes of Taurida National V.I. Vernadsky University. Series: Technical Sciences*, 1(1), 147–151. <https://doi.org/10.32782/2663-5941/2024.1.1/22>.
5. Kolomoiets, S. (2024). Application of artificial intelligence in medical image recognition. *Information Technology and Society*, (3 (14)), 23–28. <https://doi.org/10.32689/maup.it.2024.3.3>.

Наукові праці, які засвідчують апробацію матеріалів дисертації:

6. Коломоець, С. (2024). Діагностика артеріальної гіпертензії безманжетними пристроями за допомогою машинного навчання. У *Grundlagen der modernen wissenschaftlichen forschung* (О. Чумаченко, Chair). *European Scientific Platform*. <https://doi.org/10.36074/logos-13.12.2024.053>.
7. Коломоець, С. (2024). Порівняння алгоритмів машинного навчання для класифікації артеріальної гіпертензії. У *Період трансформаційних процесів в світовій науці: Задачі та виклики* (О. Чумаченко, Chair). ТОВ УКРЛОГОС Груп. <https://doi.org/10.62731/mcnd-13.12.2024.004>.

8. Коломоець, С. (2025). Порівняльний аналіз архітектур нейронних мереж: RNN, LSTM, GRU. У Проблеми та перспективи реалізації та впровадження міждисциплінарних наукових досягнень (О. Чумаченко, Chair). МЦНД. <https://doi.org/10.62731/mcnd-20.12.2024.002> .
9. Коломоець С. (2025). Порівняльний аналіз класичних діагностичних методів та методів на основі штучного інтелекту в кардіології. Theoretical and practical aspects of modern scientific research (О. Чумаченко, Chair). European Scientific Platform. <https://doi.org/10.36074/logos-24.01.2025.050>

ЗМІСТ

ЗМІСТ	12
ПЕРЕЛІК УМОВНИХ ПОЗНАЧЕНЬ.....	14
ВСТУП	15
1. ПРОБЛЕМИ ДІАГНОСТИКИ АРТЕРІАЛЬНОЇ ГІПЕРТЕНЗІЇ	19
1.1 Артеріальна гіпертензія, її ознаки та поширення.....	19
1.2 Проблеми діагностики артеріальної гіпертензії	20
1.3 Класифікація методів вимірювання артеріального тиску.....	21
1.4 Висновки до розділу 1	29
2. ІНТЕЛЕКТУАЛЬНЕ ПРОГНОЗУВАННЯ АРТЕРІАЛЬНОГО ТИСКУ НА ОСНОВІ БЕЗМАНЖЕТНОГО ВИМІРЮВАННЯ	30
2.1 Необхідність прогнозування артеріального тиску у хворих на артеріальну гіпертензію.....	30
2.2 Постановка задачі прогнозування артеріального тиску	31
2.3 Попередня обробка результатів безманжетного вимірювання артеріального тиску	32
2.3.1 Необхідність попередньої обробки результатів безманжетного вимірювання артеріального тиску.....	32
2.3.2 Метод попередньої обробки результатів безманжетного вимірювання артеріального тиску.....	33
2.4 Класифікація методів прогнозування часових рядів та метрик помилок	39
2.5 Методи прогнозування часових рядів з використанням ШНМ	42
2.5.1 Багатошаровий персептрон (MLP).....	43
2.5.2 Байєсівська нейронна мережа (BNN)	45
2.5.3 Радіальні базисні функції (RBF).....	46
2.5.4 Узагальнені регресійні нейронні мережі (GRNN).....	46
2.5.5 Регресія К-найближчого сусіда (KNN).....	47
2.5.6 Дерева рішень.....	48
2.5.7 Машина опорних векторів (SVM).....	48
2.5.8 Гаусові процеси (ГП).....	50
2.5.9 Рекурентна нейронна мережа (PHM).....	50
2.5.10. Згорткові нейронні мережі.....	58

2.5.11. Побудова гібридних нейронних для розв'язання задачі прогнозування артеріального тиску	69
2.6 Висновки до розділу 2	90
РОЗДІЛ 3. ІНТЕЛЕКТУАЛЬНА КЛАСИФІКАЦІЯ СТУПЕНЯ АРТЕРІАЛЬНОЇ ГІПЕРТЕНЗІЇ	92
3.1. Ступені артеріальної гіпертензії.....	92
3.2. Діагностика ступеня артеріальної гіпертензії.....	93
3.3. Огляд методів інтелектуальної діагностики ступеня АГ	96
3.4. Інтелектуальні ансамблеві технології.....	99
3.4.1. Беггінг	100
3.4.2. Бустинг.....	102
3.4.3. Стекінг.....	104
3.5 Постановка завдання інтелектуальної діагностики ступеня АГ	106
3.6 Побудова архітектури ансамблів нейронних мереж	107
3.7 Результати	112
3.8 Висновки до розділу 3	113
РОЗДІЛ 4. ІНФОРМАЦІЙНА ТЕХНОЛОГІЯ ІНТЕЛЕКТУАЛЬНОГО ПРОГНОЗУВАННЯ АТ НА ОСНОВІ БЕЗМАНЖЕТНОГО ВИМІРЮВАННЯ	115
4.1. Основні сценарії використання інформаційної технології	115
4.2. Задачі інформаційної технології, їх входи та виходи	118
4.3. Розробка архітектури інформаційної технології: прогнозування артеріального тиску	120
4.4 Висновки до розділу 4	122
ВИСНОВКИ.....	123
СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ.....	125
ДОДАТОК А. АКТ ВПРОВАДЖЕННЯ В ДУ «НАЦІОНАЛЬНИЙ НАУКОВИЙ ЦЕНТР ІМЕНІ АКАДЕМІКА М.Д. СТРАЖЕСКА».....	150

ПЕРЕЛІК УМОВНИХ ПОЗНАЧЕНЬ

BI-LSTM (Bidirectional Long Short-Term Memory) — Двонаправлена довга короткострокова пам'ять

GRU (Gated Recurrent Unit) — Вентильний рекурентний блок

LSTM (Long Short-Term Memory) — Довга короткострокова пам'ять

ML (Machine Learning) — Машинне навчання

RNN (Recurrent Neural Networks) — Рекурентна нейронна мережа

SVM (Support Vector Machine) — Машина опорних векторів

АГ — Артеріальна гіпертензія

АТ — Артеріальний тиск

ВООЗ — Всесвітня організація охорони здоров'я

ВОС — Всесвітня організація серця

ДАТ — Діастолічний артеріальний тиск

ЕБІ — Електричний біоімпеданс

ЕКГ — Електрокардіографія

ЕхоКГ — Ехокардіографія

ІКГ — Імпедансна кардіографія

МОЗ — Міністерство охорони здоров'я

НМ — Нейронна мережа

ПАТ — Пульсовий артеріальний тиск

САТ — Систолічний артеріальний тиск

СКГ — Сейсмокардіографія

ССЗ — Серцево-судинні захворювання

ТАГ — Тonoартеріографія

ФПГ — Фотоплетизмографія

ІІ — Штучний інтелект

ІІНМ — Штучна нейронна мережа

ІІПІХ — Швидкість поширення пульсової хвилі

ВСТУП

Актуальність теми. На сьогоднішній день серцево-судинні захворювання лишаються першими за частотою смертності як в Україні так і в світі загалом. В Україні кожен рік більше 400 тисяч осіб помирають від серцево-судинних захворювань, що складає 60% смертей. Найбільше помирають від інсультів та інфарктів міокарда, а це саме ті захворювання, яким можна і треба запобігти, серцеві напади не виникають раптово, а є наслідками образу життя та завчасної діагностики. 46% дорослих, що мають артеріальну гіпертензію, не знають про це. За даними дослідження STEPS, яке проводилось в Україні в 2019 році, підвищений артеріальний тиск мають 34,8% українців у віці від 18 до 69 років [1].

З метою покращення ситуації в цьому питанні необхідно термінове створення індивідуальний систем безманжетного вимірювання артеріального тиску у хворих з наступним його прогнозуванням у часовому просторі та діагностичних систем визначення ступеня артеріальної гіпертензії.

Штучний інтелект є на сьогодні є світовим трендом розвитку науки і техніки, який надає великі можливості по вирішенню задач прогнозування та діагностики.

З метою підвищення ефективності боротьби з наслідками серцево-судинних хвороб вимагається розробка інтелектуальних методів прогнозування артеріального тиску та діагностики визначення ступеня артеріальної гіпертензії.

Зв'язок роботи з науковими програмами, планами, темами.

Дисертаційне дослідження виконувалось відповідно до планів НДР, програм і договорів що виконувались у Національному технічному університеті України «Київському політехнічному інституті імені Ігоря Сікорського». Дисертаційне дослідження проводилося на даних ДУ «Національний науковий центр імені академіка М.Д. Стражеска» в рамках договору про співпрацю між «КПІ ім. Ігоря Сікорського» та ДУ «Національний науковий центр імені академіка М.Д. Стражеска».

Мета і завдання дослідження. Метою дисертаційного дослідження є створення методів обробки сигналів безманжетного вимірювання артеріального тиску з подальшим його прогнозуванням та розробка інтелектуальних методів класифікації типу артеріальної гіпертензії на основі використання гібридних нейронних мереж ансамблевого типу. Для досягнення мети поставлені та вирішені такі завдання:

- розробка методів інтелектуального прогнозування артеріального тиску з різними горизонтами прогнозу адаптоване під поточний стан хворого;
- розробка методів інтелектуальної діагностики артеріальної гіпертензії на основі використання гібридних нейронних мереж ансамблевого типу.

Об’єкт дослідження — методи інтелектуального прогнозування часових рядів та багатокласової класифікації.

Предмет дослідження — інтелектуальні методи прогнозу динаміки артеріального тиску та структурно-параметричного синтезу гібридних нейронних мереж для класифікації артеріальної гіпертензії та визначення її типу.

Методи дослідження базуються на положеннях:

- теорії обробки інформації;
- теорії штучного інтелекту.

Як засіб розв’язання поставлених завдань використовувалося математичне та комп’ютерне моделювання. У дослідженнях використовувались програмні пакети TensorFlow, Scikit-learn, а також мова програмування Python.

Наукова новизна отриманих результатів:

- вперше запропоновано метод для обробки даних артеріального тиску у хворих, який відрізняється тим, що на основі методів безманжетного вимірювання здійснює попередню обробку отриманих даних та подальше прогнозування на основі використання гібридних рекурентних нейронних мереж, горизонт прогнозу яких адаптовано під поточний стан пацієнта, що дає можливість знизити імовірність виникнення інсульту або інфаркту у хворих;

- удосконалено метод вирішення задачі класифікації та знижено обчислювальні витрати при машинному навчанні гібридних нейронних мереж за рахунок визначення найбільш впливових ознак артеріальної гіпертензії для різних ступенів захворювання, які крім загальних ознак (анамнез, результати огляду лікаря, результати аналізів крові, сечі, вимірювання артеріального тиску) включають результати обробки ЕКГ, ЕхоКГ;

- розроблено метод структурно-параметричного синтезу гібридної нейронної мережі для розв’язання задачі класифікації ступеня артеріальної гіпертензії, який відрізняється тим, що гібридна нейронна мережа будується на основі створення беггінг-ансамблю інтелектуальних класифікаторів, включених в ансамбль за критеріями точності та різноманіття, що дозволяє підвищити точність класифікації.

Практичне значення отриманих результатів. На підставі розробленого математичного забезпечення:

- розроблені інтелектуальні методи та алгоритми прогнозування значень артеріального тиску на основі використання без манжетного вимірювання, що дозволило підвищити рівень запобігання інсультів та інфарктів у хворих;

- розроблено новий підхід до діагностування ступеню артеріальної гіпертензії у хворих;

- використання запропонованих методів та алгоритмів у ДУ «Національний науковий центр імені академіка М.Д. Стражеска», що дозволило підвищити рівень запобігання інсультів і інфарктів у хворих.

Особистий внесок здобувача. Всі результати, які відносяться до захисту, отримані автором особисто.

Апробація результатів дисертації. Основні результати досліджень доповідалися і обговорювалися на наступних міжнародних науково-технічних конференціях:

- VII Міжнародна науково-практична конференція «Grundlagen der modernen wissenschaftlichen forschung» (Цюрих, Швейцарія);

- IV Міжнародна наукова конференція «Період трансформаційних процесів в світовій науці: задачі та виклики» (Рівне, Україна);
- VIII Міжнародна науково-теоретична конференція «Проблеми та перспективи реалізації та впровадження міждисциплінарних наукових досягнень» (Конотоп, Україна);
- V Міжнародна науково-практична конференція «Theoretical and practical aspects of modern scientific research» (Сеул, Південна Корея).

Публікації. За результатами дисертаційного дослідження було опубліковано 5 наукових публікацій, з яких 3 публікації у фахових наукових виданнях категорії «Б».

Структура та обсяг дисертації. Дисертаційна робота складається зі вступу, 4 розділів, висновків, списку використаних джерел з 210 найменувань та одного додатку. Загальний обсяг дисертації складає 150 сторінок, містить 47 рисунків та 21 таблицю.

1. ПРОБЛЕМИ ДІАГНОСТИКИ АРТЕРІАЛЬНОЇ ГІПЕРТЕНЗІЇ

1.1 Артеріальна гіпертензія, її ознаки та поширення

Артеріальною гіпертензією (АГ) називають хронічну патологію коли систолічний артеріальний тиск (САТ) вищий за 140 мм.рт.ст. та діастолічний артеріальний тиск (ДАТ) вищий за 90 мм.рт.ст. Систолічний артеріальний тиск — це тиск у судинах в момент виштовхування крові серцем. Діастолічний артеріальний тиск — це тиск, в момент коли серце відпочиває між ударами. Без належного спостереження та лікування АГ може призвести до таких ускладнень як інфаркт, інсульт, погіршення зору, серцевої або ниркової недостатності [2].

На сьогоднішній день за даними Всесвітньої організації охорони здоров'я (ВООЗ) та Міністерство охорони здоров'я України (МОЗ), серцево-судинні захворювання (ССЗ) є найбільшою причиною смертності як в Україні, так і в цілому світі [3, 4].

За останній 30 років смертність від ССЗ зросла на 60% [5]. Згідно даних Всесвітньої організації серця (ВОС) починаючи з 1990 року і до 2021 року кількість смертей збільшилося з 12,1 мільйонів людей до 20,5 мільйонів.

Згідно відкритої статистики Українського центру суспільних даних, кожен рік більше ніж 500000 українців помирають від ССЗ [6]. Смертність за типом місцевості переважає у міського населення 60% над сільським 40%. Смертність за статевими ознаками майже рівна (чоловіки 49,5%, жінки 50,5%), однак найбільший пік смертності у чоловіків припадає на проміжок 65- 69 років, а у жінок – 80-84 роки, це обумовлено віком, жінки стають більш схильними до ССЗ після менопаузи. Статистика смертності від ССЗ по рокам приведена на рисунку 1.1.




Рисунок 1.1 – Смертність від ССЗ в Україні 2018-2020 роки

Нижче представлено класифікацію типів артеріального тиску (АТ).

1.2 Проблеми діагностики артеріальної гіпертензії

Проблеми діагностики АГ полягають як в медичній площині так і в організаційній. До основних проблем діагностики АГ відносять:

- достовірність значень вимірювання тиску (високий тиск у повсякденні, але нормальний тиск при вимірювання в медичному закладі, порушення техніки вимірювання тиску, синдром «білого халату»);
- недостатність вимірювання АТ (вимірювання тиску лише при відчутті симптомів АГ або вимірювання раз на добу; правильним вважається вимірювання тиску зранку та ввечері (тричі з інтервалами та запис середнього значення));
- недостатній збір загального анамнезу та неврахування супутніх захворювань;
- використання різними закладами охорони здоров'я різної класифікації АГ, що впливає на точність постановки діагнозу (відсутність чіткої загальної стандартизації постановки діагнозу);
- недостатній контроль та обізнаність про захворювання з боку пацієнтів.

Враховуючи діагностичні проблеми АГ можна зробити висновок, що варто зосередити більше уваги на обізнаності самих пацієнтів щодо правильності вимірювання АТ, акценті на правильних умовах вимірювання, безперервному вимірюванні АТ щоб мати змогу проаналізувати великі обсяги даних зміни тиску у пацієнта протягом усієї доби для уникнення недостовірних показників АТ та можливості попереджати гіпертонічні проблеми до їх критичних проявів. Для покращення даного питання варто розглянути метод класифікації артеріального тиску, стандартизувати системи класифікації під єдиний стандарт та створити системи безперервного моніторингу АТ з можливістю попередження пацієнта про подальші необхідні дії для запобігання виникнення серцево-судинних ускладнень спричинених АГ.

1.3 Класифікація методів вимірювання артеріального тиску

Існують чіткі регламентації та вимоги до вимірювання АТ та приладів за допомогою яких проводяться виміри. Існують два основні методи вимірювання АТ – інвазивний (прямий, з прониканням вимірювальних пристроїв у артерію) та неінвазивний (непрямий, вимір відбувається за допомогою датчиків на поверхні шкіри пацієнта).

Зазвичай інвазивний метод використовують лише в стаціонарних умовах при хірургічних втручаннях [7]. В артерію вводиться зонд з датчиком тиску, завдяки цьому можна моніторувати тиск безперервно, спостерігаючи за співвідношенням показників тиску протягом часу, це і є найбільшою перевагою цього методу. Однак цей метод можна використовувати тільки під наглядом спеціалістів враховуючи ризики які він несе. Поява тромбозу або гематоми у місці операційного втручання, інфекційне ураження, можлива кровотеча при забиранні зонду, усі ці недоліки роблять інвазивний метод придатним для використання лише при операційних втручаннях під наглядом спеціалістів і зовсім не підходять для моніторування та прогнозування АТ у людей в повсякденному житті.

В свою чергу неінвазивний метод має набагато більшу розгалуженість та розповсюдженість у методах вимірювання тиску та поділяється на аускультативний, осцилометричний та пальпаторний.

На сьогоднішній день усі пристрої для неінвазивного виміру АТ можна розділити на два типи: манжетні та безманжетні.

На сьогоднішній день у світі існують зручні портативні технології ґруновані на безманжетному вимірюванні АТ, які використовують датчики, обробку сигналу та штучний інтелект для точності роботи. Головним суперечливим питанням є стандарти ААМІ/ESH/ISO які розроблені для манжетного вимірювання АТ, однак вони зовсім не підходять для стандартизації безманжетних пристроїв через різницю в підходах до вимірювань. Більшість безманжетних пристроїв потребує періодичного калібрування з використанням значень АТ, виміряних за допомогою манжетних пристроїв. Також необхідно враховувати що деякі безманжетні пристрої можуть потребувати інформації про пацієнта (вага, вік, зріст, стать), тобто не вимірювати АТ, а відстежувати зміни в АТ за допомогою штучного інтелекту.

Найбільш поширеними технологіями для вимірювання АТ за допомогою безманжетних пристроїв є:

- Фотоплетизмографія (ФПГ)

ФПГ з'явилася як перспективний неінвазивний метод моніторингу АТ та серцево-судинної функції [8]. Він працює шляхом освітлення тканин світлом і збору світла, яке пропускається або відбивається. Світло змінюється через поглинання гемоглобіну в пульсуючій артеріальній крові. Цей оптичний сигнал виявляється або датчиком, розміщеним на протилежному боці тканини (передавальний ФПГ), або відбиваючим датчиком, розташованим на тій самій стороні і в тій самій площині, що й випромінювач світла (відбиваючий ФПГ). Статичні компоненти, включаючи м'язи, жир, шкіру та інші тканини, складають понад 95% амплітуди світла, в той час як на решту динамічної складової впливають об'ємні зміни в судинах, викликані серцебиттям, які

можна виявити за допомогою пульсації [9]. Як наслідок, форма хвилі ФПГ містить цінну інформацію про серцево-судинну динаміку і демонструє тісний зв'язок з АТ [10]. Аналіз пульсової хвилі (Pulse wave analysis, PWA) [11] дозволяє виділити з сигналів ФПГ особливості, пов'язані з артеріальною пульсацією. Завдяки простоті отримання сигналів ФПГ за допомогою фотоелектричних датчиків, безперервний безманжетний моніторинг АТ привернув значну увагу медичної спільноти. Більше того, сигнали ФПГ можуть бути легко інтегровані в носимі пристрої [12], такі як смартфони [13, 14] та смарт-годинники [15]. В останніх дослідженнях спостерігається значний інтерес до безманжетного вимірювання АТ з використанням методів вимірювання на основі ФПГ [16].

- Електрокардіографія

Електроди використовують різницю напруги на серці для вимірювання електричної активності серця, яка ініціює механічне скорочення. Спочатку припускали, що оцінка АТ виключно за електрокардіограмою є можливою [17], але нещодавно було доведено, що такий підхід є ненадійним [18]. ЕКГ дає цінну інформацію про серцевий цикл.

- Балістографія

Балістокардіографія (БКГ) - це неінвазивна методика, яка використовується для вимірювання механічних рухів людського тіла у відповідь на викид крові з серця під час кожного серцебиття. Давно встановлено, що тіло проявляє тонкі рухи з кожним серцебиттям [19], що представляють собою відповідь на викид крові серцем в артерії. Для виявлення та реєстрації цих рухів у різних частинах тіла були створені різноманітні прилади. Записана балістокардіограма надає інформацію про час і силу кожного серцебиття, а також певні аспекти серцевої функції [20]. Цей метод можна використовувати для багатьох різних видів зондування, але він також може створювати артефакти руху [21], які потрібно ретельно продумувати при аналізі та інтерпретації сигналів.

– Електричний біоімпеданс

Електричний біоімпеданс (ЕБІ) - це метод вимірювання електричних властивостей біологічних тканин. Він ґрунтується на тому, що різні тканини в організмі по-різному проводять електрику [22]. Цей метод є неінвазивним і може надати цінну інформацію про різні фізіологічні параметри, включаючи АТ [23]. Він пропонує більшу глибину проникнення, ніж ППГ, є простішим, ніж ультразвук [24], але не дає такої ж високої якості хвильових форм. Коли йдеться про вимірювання АТ, електричний біоімпедансний метод зазвичай включає в себе специфічний варіант, відомий як «біоімпедансна плетизмографія» або «імпедансна кардіографія (ІКГ)». Основний принцип полягає в тому, що зміни об'єму крові в артеріях викликають зміни електричного імпедансу, які можна виявити за допомогою електродів, розміщених на шкірі [25]. Зазвичай набір з чотирьох електродів розміщують на грудній клітці, подаючи нешкідливий електричний струм і вимірюючи результуючу напругу. В результаті можна отримати електричний імпеданс, який змінюється в основному через високопровідну пульсуючу кров. Безперервно відстежуючи ці зміни, сигнал ІКГ можна обробляти і використовувати для визначення гемодинамічних параметрів, включаючи систолічний і діастолічний тиск [26]. Було продемонстровано, що ІКГ є цінним інструментом для безперервного неінвазивного моніторингу в конкретних клінічних ситуаціях [27], таких як під час фізичного навантаження. Ця методика може бути застосована до різних ділянок тіла [28]. Системи на основі біоімпедансу долають обмеження оптичних систем, оскільки модальність залежить від розподілу дуже мінімального, неінвазивного, високочастотного змінного струму під шкірою, а запис сигналу напруги базується на об'ємному розподілі різних типів тканин з їх унікальними електричними характеристиками. Доведено, що ці системи ефективно реєструють артеріальний кровотік, коли біоімпедансні електроди контактують зі шкірою і вирівнюються з підшкірною артерією [29].

– Сейсмокардіографія

Сейсмокардіографія (СКГ) передбачає запис та аналіз коливань грудної стінки, що виникають при скороченні серця, для отримання уявлення про серцево-судинну функцію за допомогою акселерометрів або датчиків руху [30]. Ця методика може оцінити артеріальний тиск неінвазивно, оскільки насосна дія серця генерує характерні форми хвиль, які можна співвіднести зі змінами АТ під час серцевого циклу. Аналізуючи форми хвиль СКГ, дослідники та клініцисти можуть виявити специфічні патерни, пов'язані зі змінами АТ. Ці патерни можуть бути пов'язані з систолічним і діастолічним АТ [31]. Морфологія сейсмокардіограми демонструє ідентифіковані опорні точки, що дозволяє виявляти важливі події, такі як відкриття аортального клапана [32]. В даний час проводяться постійні дослідження [33], оскільки необхідно більше досліджень для валідації та підвищення точності і надійності СКГ для вимірювання АТ. Було визначено, що позиціонування датчика та артефакти руху є ускладнюючими факторами [34].

– Датчики тиску

Тонартеріографія (ТАГ), або аплікаційна тонометрія, передбачає прикладання датчика тиску до шкіри поверхнево до периферичної артерії для запису кривої тиску [35]. Датчик тонометрії чинить тиск на певну артерію, викликаючи сплющення (або аппланацію) стінки артерії. Це знімає окружний натяг кровоносної судини, отже, єдиним компонентом сили, що реєструється, є компонент, зумовлений внутрішньоартеріальним тиском. Датчики ТАГ можуть перетворювати входи тиску в електричні виходи [36]. Аналізуючи отриману осцилограму, датчик обчислює пульсовий тиск і пропонує оцінку АТ [37]. Перевага аплікаційної тонометрії полягає в тому, що вона може використовувати унікальний одноточковий датчик, який можна легко наносити на м'які поверхні, такі як шкіра людини [38, 39]. Були досліджені різні механізми вимірювання тиску [40].

Нещодавня розробка гнучких датчиків тиску проклала шлях до покращення серцево-судинного моніторингу за цим принципом [41]. Нові

вдосконалені датчики можуть фіксувати більш детальні характеристики пульсових хвиль [42]. Ці нові датчики легкі, прилягають до шкіри, біосумісні, стабільні, недорогі та малопотужні, що робить їх придатними для різноманітних застосувань [43]. Дослідження безманжетного вимірювання АТ за допомогою гнучких датчиків тиску продемонстрували багатообіцяючі результати [43].

– Ультразвук

Ультразвук дозволяє оцінити абсолютний об'єм крові, площу поперечного перерізу та форми хвиль швидкості кровотоку в артерії за допомогою М-режиму та принципів доплерографії [45]. Помітною перевагою над ФПГ є його здатність проникати в глибокі артерії для кращої візуалізації. Тим не менш, існують обмеження, які слід враховувати, включаючи значний розмір ультразвукових генераторів, необхідних для цього підходу, що ускладнює його інтеграцію з динамічним датчиком.

На сьогоднішній день існує низка портативних пристроїв манжетного та безманжетного типів. Порівняння даних типів пристроїв наведено в таблиці 1.1.

Таблиця 1.1

Порівняння манжетних та безманжетних пристроїв

№	Характеристика пристроїв	Манжетні	Безманжетні
1	Вимірювання тиску з фіксацією часу	Так	Так
2	Електрокардіографія (ЕКГ)	Ні	Так
3	Пульсоксиметрія	Ні	Так
4	Актіграфія	Ні	Так
5	Швидкість поширення пульсової хвилі в аорті (ШППХ)	Ні	Так
6	Портативність	Ні	Так

З таблиці 1.3 можна зробити висновок, що безманжетні типи пристроїв мають ширший спектр застосування, що в поєднанні з їх портативністю дозволяє зручно носити на тілі пристрій для цілодобового моніторингу стану пацієнта. Приклади найпоширеніших безманжетних пристроїв для вимірювання тиску наведено в таблиці 1.2.

Таблиця 1.2

Безманжетні пристрої для вимірювання АТ

№	Назва пристрою	Вигляд	Особливості
1	SOMNOtouch NIBP		Вимірювання АТ з фіксацією часу, ЕКГ, пульсоксиметрія, актіграфія, ШППХ, моніторинг стану пацієнта через застосунок портативність
2	BioBeat		Вимірювання АТ з фіксацією часу, моніторинг стану пацієнта через застосунок, портативність
3	Asus VivoWatch BP		Вимірювання АТ з фіксацією часу, ЕКГ, пульсоксиметрія, моніторинг стану пацієнта через застосунок портативність

№	Назва пристрою	Вигляд	Особливості
4	Turister S3 Smart		Вимірювання АТ з фіксацією часу, ЕКГ, вимірювання кількості кроків, моніторинг фаз сну, моніторинг стану пацієнта через застосунок портативність
5	Samsung Galaxy Watch FE		Вимірювання АТ з фіксацією часу, ЕКГ, пульсоксиметрія, моніторинг стану пацієнта через застосунок портативність

Проведені дослідження з метою порівняння безманжетного визначення артеріального тиску зі значеннями, отриманими при манжетному вимірюванні за методом Короткова при використанні кореляційного аналізу, t-критерію Стьюдента, методу Бленда-Алтмана для розрахунку стандартне відхилення різниці та 95% довірчий інтервал показали, що статистично значущих відмінностей за середніми значеннями САТ і ДАТ для двох методів вимірювання не виявлено. Відзначено сильний прямий зв'язок між показниками САТ і ДАТ, виміряними двома методами. Зсув (Bias) для САТ і ДАТ становив: -0,5 мм рт. ст. і -0,3 мм рт. ст. відповідно. Різниця вимірювань ДАТ залежала від рівня АТ. Заниження значень ДАТ було більш вираженим для низьких АТ від 55 до 75 мм рт. ст.

1.4 Висновки до розділу 1

На основі проаналізованих джерел літератури встановлено, що для підвищення точності прогнозування рівня АТ доцільне постійне вимірювання АТ, цього можливо досягти використовуючи лише безманжетний тип вимірювання, оскільки традиційні манжетні пристрої роблять вимірювання з великими інтервалами, що робить вибірку з такими даними неточною для прогнозування.

Встановлено, що для приладів безманжетного вимірювання АТ існують найбільш перспективні методи, такі як фотоплетизмографія, електрокардіографія та пульсооксиметрія, які дозволять зробити комфортним безперервне вимірювання АТ.

Встановлено доцільність подальшої неперервної інтелектуальної обробки даних з метою виконання прогнозу артеріального тиску на певний часовий період, що дозволить запобігти таким гострим станам як інфаркт або інсульт.

2. ІНТЕЛЕКТУАЛЬНЕ ПРОГНОЗУВАННЯ АРТЕРІАЛЬНОГО ТИСКУ НА ОСНОВІ БЕЗМАНЖЕТНОГО ВИМІРЮВАННЯ

2.1 Необхідність прогнозування артеріального тиску у хворих на артеріальну гіпертензію

На сьогоднішній день здоров'ю населення планети суттєво загрожують артеріальна гіпертензія, високий артеріальний тиск, від яких страждає понад мільярд людей у всьому світі. Гіпертензія також є основним фактором ризику серцево-судинних захворювань, інсульту та ниркової недостатності. Помітно, що значний відсоток як смертей від серцевих захворювань, так і смертей від інсульту пов'язаний з гіпертонією. У сфері охорони здоров'я відбуваються прориви, але в країнах з низьким і середнім рівнем доходу, де доступ до медичних послуг часто обмежений, гіпертонія часто не діагностується, а отже, і не лікується. Гіпертензія може відігравати значну роль у збільшенні кількості серцевих нападів та ішемічної хвороби серця [46].

Безперервний моніторинг артеріального тиску (АТ) має вирішальне значення в умовах інтенсивної терапії, таких як операційні та відділення інтенсивної терапії [47]. Раптові зміни АТ можуть сигналізувати про погіршення стану пацієнта або побічні реакції на лікування [48]. Однак періодичні вимірювання за допомогою манжети можуть пропустити гострі зміни, що спонукає до досліджень безманжетного вимірювання АТ за допомогою фізіологічних сигналів [49].

Для ефективного та точного прогнозування динаміки АТ використовуються моделі прогнозування часових рядів. Прогнозування артеріального тиску потенційно може допомогти лікарю вжити превентивних заходів ще до того, як виникнуть небезпечні медичні ситуації. Вважається доцільним прогнозувати артеріальний тиск на 30 хвилин вперед[50].

Узагальнені моделі були розроблені, але часто не враховують індивідуальні варіації регуляції АТ [51], що ускладнює досягнення узгодженої продуктивності в реальних умовах. Наприклад в роботі [52] було

запропоновано метод на основі PPG із середньою абсолютною похибкою (MAE) 9,43 мм рт.ст. для систолічного артеріального тиску (САТ), а Sun та ін. [53] повідомили про стандартне відхилення (SD) 7,97 мм рт.ст. для САТ, що підкреслює обмеження в точності узагальнених моделей САТ. Для вирішення цієї проблеми все більшої уваги набуває персоналізована оцінка АТ [54, 55]. Leitner та ін. [53] розробили модель BP-CRNN-трансферу з використанням попереднього навчання та точного налаштування, яка покращила точність прогнозування, але включала складні кроки, непридатні для клінічної практики. Wang та ін. [56] розробили легку персоналізовану модель для довготривалого відстеження АТ, хоча вона була обмежена одним сценарієм. Padiaditis та ін. [57] продемонстрували, що індивідуалізовані моделі значно зменшують помилки порівняно з моделями групового рівня. Розглянемо більш детально методи прогнозування часових рядів.

В даній роботі пропонується новий метод інтелектуального прогнозування артеріального тиску, який полягає у послідовному застосуванні двох алгоритмів:

- інтелектуальна попередня обробка результатів безманжетного вимірювання артеріального тиску;
- інтелектуальне прогнозування артеріального тиску пацієнта на основі результатів інтелектуальної попередньої обробки результатів без манжетного вимірювання.

2.2 Постановка задачі прогнозування артеріального тиску

Нехай часовий ряд значень артеріального тиску представлений послідовністю $\{y_t\} = 1, \dots, N$, де y_t виміряне значення в момент часу t . У цьому дослідженні застосовується авторегресійний підхід до прогнозування, заснований на гіпотезі, що майбутнє значення часового ряду певним чином залежить від його попередніх (доступних) спостережень. Відповідно, спираючись на наявні дані, можна з певною точністю передбачити розвиток ряду в майбутньому.

Формалізація задачі прогнозування включає наступні компоненти:

- Вибірка з попередніми даними $\{y_t\} = 1, \dots, N$.
- Глибина прогнозу $h = 1, 2, \dots$, який визначає кількість майбутніх періодів, для яких слід здійснити прогнозування.
- Цільовий функціонал $F: \Omega \rightarrow R$, що оцінює точність і ефективність прогностичної моделі. Тут Ω позначає множину усіх допустимих авторегресійних моделей.

Мета:

Вибрати оптимальну авторегресійну модель для формування прогнозу за виглядом $\hat{y}_{t+h} = f^*(y_t, \dots, y_{t-k+1})$, яка оптимізує значення критерію якості: $f^* = \operatorname{argmax}_{f \in \Omega} \{F(f)\}$.

2.3 Попередня обробка результатів безманжетного вимірювання артеріального тиску

2.3.1 Необхідність попередньої обробки результатів безманжетного вимірювання артеріального тиску

Для багатьох пацієнтів є вагомим факт полегшення та спрощення самостійного вимірювання АТ. Тому використання безманжетного визначення тиску є перспективним і має переваги. Так, пацієнти отримають зручність, більшу незалежність та постійний контроль за станом свого здоров'я, коли звичайний смартфон підключають до монітору, який має вигляд чохла для телефону. Також перевагою стане вимірювання АТ в будь-якому місці та в будь-який час. У деяких пацієнтів вимірювання тиску в медичному закладі може провокувати гіпертонію «білого халата». Цей фактор нівелюється при проведенні вимірювань в домашніх умовах, а результати стають достовірнішими. За допомогою телемедичних технологій показники домашніх вимірювань можливо передати лікарю, а це полегшить підбір медичних препаратів та їх дозування. Підсумком стане зниження захворюваності та смертності пацієнтів з АГ [58, 59].

Використання моделі машинного навчання [60-62] потребує вивчення впливу перешкод на точність вимірювання АТ. Якість запису ФПГ впливає на визначення АТ безманжетним методом. Це є серйозним моментом. Реєстрація ЕКГ та ФПГ в цьому дослідженні проводилась з пальців рук та не враховувались особливості кровонаповнення пальців (об'єм пальця, температура, вологість). Цей момент потребує більш широкого вивчення. В цій роботі використовувались тільки неінвазивні методи для контролю вимірювання АТ, що також стало недоліком. Розподіл за рівнем АТ є нерівномірним – були практично відсутні пацієнти з високими та низькими показниками АТ. Були також відсутні пацієнти з дефіцитом ваги та ожирінням 2-го та 3-го ступенів. Точність даного методу вимірювання АТ підвищиться, якщо розподіл за значенням ІМТ, рівнем тиску та іншими клінічними показниками буде рівномірним.

2.3.2 Метод попередньої обробки результатів безманжетного вимірювання артеріального тиску

Матеріали підрозділу 2.2.1 вказують на існування перешкод, які впливають на метод безманжетного вимірювання АТ. Наслідком є додаткове зниження точності прогнозування. З технічної точки зору для більш точних прогнозів та класифікацій швидкої конвергенції (більш ефективного навчання) потрібні якісні дані. Усунення факторів, що шкодять підвищенню якості даних дасть можливість використовувати їх для розв'язання задач класифікації та прогнозування. Упереджені дані, викиди, шкали варіантів, пропущені випадки та багатомірні дані – це перешкоди, які треба усунути на шляху підвищення якості даних.

Попередня обробка – метод, що оцінюється на основі впливу на дані та на модель прогнозування.

Етап попередньої обробки необхідний для відповідності вхідним вимогам, підвищення ефективності навчання штучного інтелекту та точності вихідних даних. Цей етап потребує структурованого та уніфікованого підходу, так як є досить трудомістким та складним. Методи попередньої обробки даних

будуть розглянуті за різними категоріями, що надасть розширений та структурований перелік методів попередньої обробки даних числових часових рядів.

Літературні джерела дають загальне розуміння попередньої обробки даних. Це набір операцій, що перетворюють необроблені масиви інформації в якісні вхідні дані. Зменшення розмірності, нормалізація, виявлення викидів—це операції попередньої обробки даних [63-66]. Якісні вхідні та вихідні дані важливі, особливо для мереж та моделей ШІ. Саме для досягнення якості використовують етап попередньої обробки даних. Проблема вихідних даних може бути несумісність (формат, розмір тощо), упередження, наявність викидів та надлишкових значень. Висока розмірність та неоднорідність даних створює додаткові перешкоди. Перед аналізом дані проходять декілька операцій попередньої обробки. Завдання операцій, їх послідовність, параметри та оптимальне місце виконання будуть залежати від типу та джерела даних, доступних ресурсів, програми, системного контексту, типу алгоритму, що використовує дані. Цілісна таксономія попередньої обробки даних представлена на рис. 2.1.

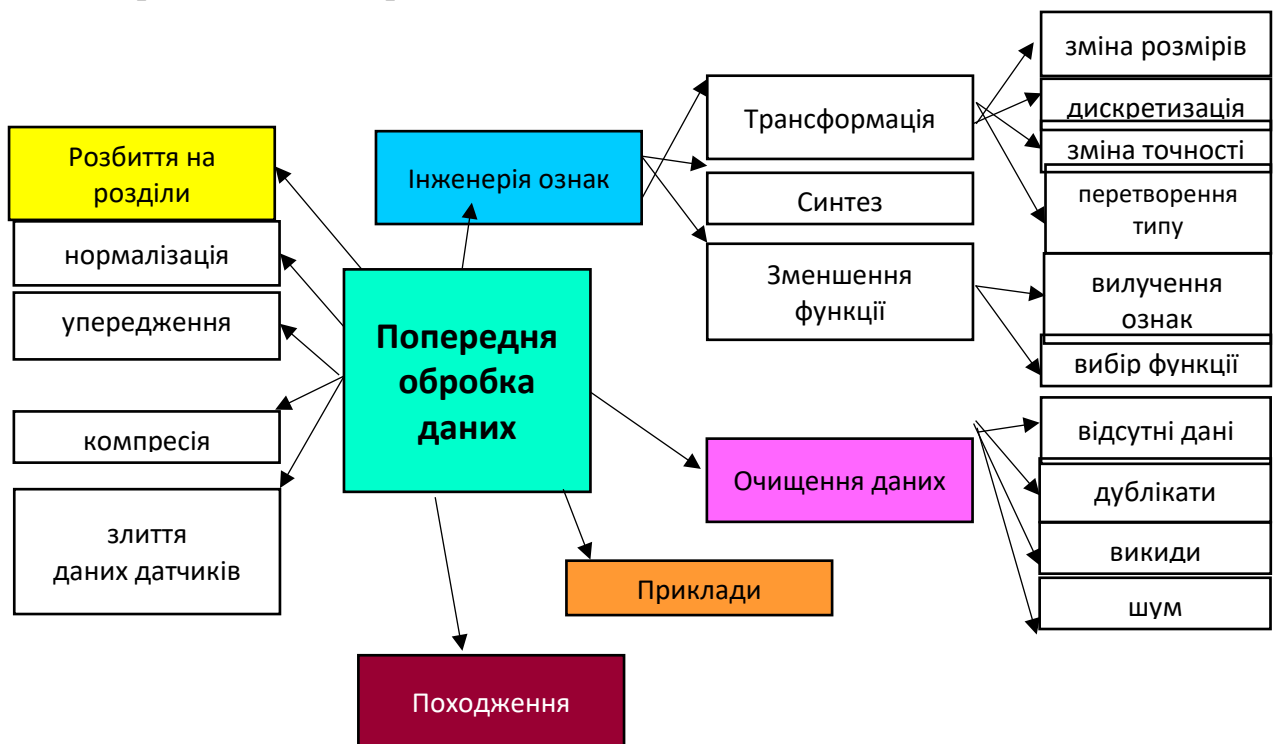


Рис. 2.1 – Таксономія попередньої обробки даних.

Нормалізація, усунення аномальних збоїв (викидів), очищення даних, пошук відсутніх даних – ті задачі, які розв’язує запропонований метод попередньої обробки результатів безманжетного вимірювання артеріального тиску.

Нормалізація попереджає зміщення в бік об’єктів з більшими величинами. Це важливий та ефективний крок попередньої обробки для алгоритмів на основі відстаней, враховуючі K -найближчих сусідів (K -NN), кластеризацію K -середніх, машину опорних векторів (SVM). Вирівнюючи вплив та важливість шкал ознак, нормалізація запобігає збільшенню впливу на навчання широких діапазонів або більших величин.

Методи нормалізації даних: нормалізації P -Norm [67], Min-Max [64, 67, 68], логарифмічне масштабування, лінеаризація степеневого розподілу [68], перетворення Бокса-Кокса [69], стандартизація [63, 64, 68, 70-74]. Їх застосування виправдане до числових даних датчиків на межі, якщо використати локальну або глобальну статистику даних.

Вилученню знань і роботі моделей перешкоджають викиди, які є прикладами зашумлених даних [63, 64]. Фальсифікуючі міри подібності, викиди призводять до неправильних класифікацій. Викиди класифікують як:

- глобальні викиди – точки даних сильно відхиляються від усього набору даних [70];
- локальні викиди – точки даних значно відхиляються від навколишніх значень (локальної області), але знаходяться в межах нормального діапазону всього набору даних [70];
- контекстуальні (умовні) викиди – точки даних значно відхиляються в деякому контексті (місцезнаходження, час тощо) [70];
- колективні викиди - точки даних разом відхиляються від решти набору даних [70].

Наступні методи використовуються для виявлення пропусків:

- медіанне абсолютне відхилення (MAD) – метод на основі статистики є надійним шкальним одновимірним оцінювачем. Він виявляє позитивні та

негативні відхилення від медіани відсортованого набору даних [75]. Є менш ефективний для асиметричних розподілів та окреслює рівну дисперсію по обидва боки від медіани (симетрію) [75]. MAD використовують на краю для знаходження локальних викидів в межах вікна;

- тест Граббса [76] або тест максимального нормалізованого залишку. Застосовується до даних з гауссовим розподілом і є одновимірним статистичним методом виявлення викидів. Метод є ітеративним і за наявності декількох викидів створює нові набори даних, які усувають викиди, визначені на попередній ітерації;

- тест узагальненого екстремального відхилення (Generalized Extreme Studentized Deviate, GESD) усуває чималі викиди в одновимірних наборах даних з нормальним розподілом, проте потребує лише верхню межу для очікуваної кількості викидів.

Помилки у процесі вилучення вартості, фальшива інформація, невірні висновки про реальний світ є наслідком аномалії даних. Такі помилки дорого коштують. Аномалії здатні поширюватися потоком даних, їх присутність і вплив посилюються в моделях і результатах. Все це підкреслює важливість їх ретельної елімінації на ранніх етапах. Виявлення та обробка аномалій – це процес очищення даних, який робить їх неякісними, в тому числі викиди, відсутні та зашумлені дані [64, 65, 77].

Ще один метод виявлення викидів - клас робастних оцінок. Так, чутливими до викидів є оцінка максимальної та логарифмічної правдоподібності. Наявні викиди в наборі даних підтягують оцінки. Чутливою до викидів є міра відстані Махаланобіса. Робастні оцінки застосовують для обчислення багатовимірного середнього та коваріації гауссового розподілу, які є сталим до пропусків у наборі даних [78].

Некерований алгоритм виявлення викидів на основі квантилів називається машиною опорних векторів одного класу (OCSVM). Цей алгоритм визначає межу прийняття рішень для нормальних даних, підбираючи гіперплощину, яка максимізує відстань від початку координат. В цьому

випадку викидами вважаються точки даних, які виходять за межі, тобто близькі до початку координат. За допомогою нелінійних ядерних функцій вивчаються межі прийняття рішень та облік викидів. Ці функції неявно відображають точки даних у вимірний простір ознак, віддалений від початку координат [79].

Результати використання методів GESD та 3 STD, що виявляють та очищують аномалії для попередньої обробки вимірювань АТ наведено на рис.2.2.




Рисунок 2.2 – Результати використання методів GESD та 3 STD для виявлення та очищення аномалій для попередньої обробки вимірювань артеріального тиску

Найпоширенішою проблемою якості, що зустрічається в сенсорних даних, є пропущені значення. Відсутні дані спричиняють помилки (розповсюдження NaN), вносять упередження та шкодять роботі моделей [64, 80]. Якщо є нульові значення, статистичні операції неможливі. Відсутність даних можна представити зарезервованими значеннями та категоріями. Проте, це шлях до упереджених висновків і результатів, що вводять в оману [70].

Відкидання вибірки або ігнорування пропущених даних, що відтискає цілі рядки, які містять пропущені значення [64, 70, 80], відновлення пропущених даних шляхом підстановки або оцінки – це методи пошуку відсутніх значень. Більш ефективними є методи відновлення пропущених даних. Так вони зберігають усі вибірки і намагаються правдоподібно

відновити відсутні екземпляри. Найпростішим методом одновимірної імплікації, є інтерполяція пропущених значень із зарезервованими категоріальними або неперервними значеннями. Та цей метод вносить зміщення і зменшує варіативність набору даних [63, 77]. Також традиційними методами імплементації є застосування попередніх або наступних значень.

Популярними методами одновимірної імплікації є використання середнього значення нормальних розподілів, медіани для асиметричних розподілів, що заповнюють пропущені випадки [63, 77, 80, 81].

Щоб знайти відсутнє значення між двома точками в лінійних даних часових рядів застосовують кусково-лінійну інтерполяцію (КЛІ). Поліноміальна інтерполяція є менш ефективною для нелінійних даних, ніж кусково-кубічна сплайн-інтерполяція (КІ), яка дає точніші результати. Згладжені криві, та як наслідок кращі апроксимації для нелінійних даних, забезпечуються кубічним сплайном та його першою та другою похідною, які є неперервними функціями [82].

KNN-класифікація для дискретних даних та kNN-регресія для неперервних даних – два різновиди імплікації за методом найближчого сусіда (kNN). Використання метрики відстані (Евклідова, Манхеттенська, Махаланобіса, Мінковського тощо) дає визначення схожості ознак між вибірками, а з параметром k визначає сусідів для даної вибірки. Із заданим значенням k та на основі предикторів будується kNN-модель з навчальної вибірки. Для прогнозування відсутніх значень змінної відгуку використовується ця модель [64, 83].

SVM-регресія (SVR) для визначення відсутніх значень безперервних змінних і SVM-класифікація (SVC) для визначення відсутніх значень категоріальних даних – два варіанти багатовимірної нелінійної техніки моделювання машини опорних векторів (SVM) [84, 85].

На рис. 2.3. наведено результати використання методів заповнення відсутніх даних (ресемплінг, кускова інтерполяція) для попередньої обробки вимірювань АТ.




Рисунок 2.3 – Результати використання методів заповнення відсутніх даних (ресемплінг, кускова інтерполяція) для попередньої обробки вимірювань артеріального тиску

На рис. 2.4 наведено результати використання методу Infinite impulse response для очищення шумів для попередньої обробки вимірювань артеріального тиску.




Рисунок 2.4 – Результати використання методу Infinite impulse response для очищення шумів для попередньої обробки вимірювань артеріального тиску

2.4 Класифікація методів прогнозування часових рядів та метрик помилок

Існує багато різних типів моделей прогнозування часових рядів, кожна з яких має свої сильні та слабкі сторони [86]:

- модель авторегресії (AR);
- модель ковзного середнього (MA);
- модель авторегресійного ковзного середнього (ARMA);

- модель авторегресійного інтегрованого ковзного середнього (ARIMA);
- модель сезонної авторегресії з інтегрованим ковзним середнім (SARIMA);
- модель векторної авторегресії (VAR);
- модель векторної корекції помилок (VECM);
- модель авторегресійного дробово-інтегрованого ковзного середнього (ARFIMA);
- експоненційно зважене ковзне середнє (EWMA);
- модель авторегресійної умовної гетероскедастичності (ARCH);
- узагальнена авторегресійна умовна гетероскедастичність (GARCH), GARCH-M, E-GARCH, T-GARCH, ST-GARCH, ABS-GARCH;
- штучні нейронні мережі.

Метрики помилок

Наведено метрики помилок, які використовуються для оцінки прогнозів на позавибірковій ділянці даних.

Для оцінки якості прогнозу середньоквадратична помилка (MSE) - це загальноприйнята метрика для порівняння моделей часових рядів. Її невід'ємність, а також симетричність є дуже цінними характеристиками [87].

$$MSE = \frac{1}{n} \sum_{i=1}^n (X_i - Y_i)^2 \quad (2.1)$$

також X_i - прогнозоване цільове значення на часовому кроці i , Y_i - дійсне цільове значення на часовому кроці i ; n кількість прогнозованих часових кроків.

Хоча MSE має симетричність, середньоквадратична помилка (RMSE) оцінює більші помилки сильніше, ніж менші, що робить її більш чутливою до викидів і карає за них [88]. Цю властивість слід мати на увазі, вона може бути як корисною, так і негативною. Тому цю метрику використовують залежно від контексту. У сфері прогнозування попиту може бути корисно використовувати цю метрику для оцінки моделей, оскільки великі помилки в

прогнозі призводять до значних економічних втрат, наприклад, у вигляді надмірних запасів.

$$RMSE = \sqrt{\sum_{i=1}^n \frac{(X_i - Y_i)^2}{n}} \quad (2.2)$$

також X_i це прогнозоване цільове значення на кроці часу i ; Y_i - дійсне цільове значення на часовому кроці i ; n - кількість прогнозованих часових кроків.

Оскільки обидві раніше згадані метрики не масштабуються, їх важко порівнювати між часовими рядами та між кількома моделями. Kolossa та Siemsen [89] пропонують для переривчастих часових рядів масштабувати RMSE за загальним середнім значенням тестового набору, щоб отримати масштабовану міру похибки, яку можна порівнювати між часовими рядами. Для цієї метрики використовувалось позначення S-RMSE.

$$S - RMSE = \frac{RMSE}{\frac{1}{n} \sum_{i=1}^n Y_i} \quad (2.3)$$

також Y_i - справжнє цільове значення на часовому кроці i ; n - кількість прогнозованих часових кроків.

Симетрична середня абсолютна відсоткова похибка (sMAPE), яка спочатку використовувалася в конкурсі МЗ для оцінки методів, що беруть участь у конкурсі, визначається наступним чином:

$$sMAPE = \frac{2}{k} \sum_{t=1}^k \frac{|Y_t - \hat{Y}_t|}{|Y_t| + |\hat{Y}_t|} * 100\% \quad (2.4)$$

також k - горизонт прогнозування; Y_t - фактичні спостереження та \hat{Y}_t - прогнози, отримані моделлю в точці t . Оскільки sMAPE карає за великі додатні помилки більше, ніж за від'ємні [88], на доповнення до нього було запроваджено MASE [89]. Він визначається наступним чином:

$$MASE = \frac{1}{k} \frac{\sum_{t=1}^k |Y_t - \hat{Y}_t|}{\frac{1}{n-m} \sum_{t=m+1}^n |Y_t - \hat{Y}_t|} \quad (2.5)$$

де n - кількість доступних історичних спостережень, а m - частота часового ряду. MASE, серед інших характеристик, не залежить від масштабу даних, його значення менше одиниці, якщо прогноз точніший, ніж середній

прогноз сезонного наївного бенчмарку, і більше одиниці, якщо він менш точний.

2.5 Методи прогнозування часових рядів з використанням ШНМ

Останнім часом значно зросло прогнозування часових рядів за допомогою ШНМ. Основним принципом ШНМ вважається фрагментація вхідних сигналів через приховані шари (один або більше), які складаються з прихованих блоків (вузлів), що робить зв'язаними кінцевий та проміжний виходи [90]. Основними перевагами ШНМ є: нелінійність, навчання на даних та зміна структури на основі інформації (внутрішньої або зовнішньої), пошук закономірностей між даними. ШНМ адаптують нерівномірності та незвичні ознаки у часовий ряд. Основними недоліками ШНМ є: можливе надмірне заповнення вибірки навчальними даними [91], тривалий час навчання та велика кількість параметрів, які мають бути підібрані експериментальним шляхом [92].

Рекурентні нейронні мережі добре зарекомендували себе для прогнозування часових рядів (навчання з учителем, дані послідовні). Вони можуть запам'ятовувати попередні дані, що корисно для прогнозування залежного від часу.

Точність методів машинного навчання (ML)

Методи ML з плином часу набувають дедалі більшої популярності у зв'язку зі зростанням інтересу до ШІ. Їх використовують для прогнозування фінансових рядів [93,94], напряму руху фондового ринку [95], макроекономічних змінних [96], бухгалтерської балансової інформації [97] та безлічі інших застосувань, що охоплюють широкий спектр галузей [98]. Подальше активне використання ML залежить від створення нових методів ML і розробки нових способів підвищення їхньої точності [99,100] та обчислювальної ефективності.

Була порівняна ефективність ML-моделей та традиційних статистичних методів щодо їх точності прогнозування [99]:

1. Багатошаровий персептрон (MLP)
2. Байєсівська нейронна мережа (BNN)
3. Радіальні базисні функції (RBF)
4. Узагальнені регресійні нейронні мережі (GRNN)
5. Регресія К-найближчого сусіда (KNN)
6. Дерева регресії CART
7. Регресія з опорними векторами (SVR)
8. Гаусові процеси (GP)
9. Рекурентні нейронні мережі
10. Згорткові нейронні мережі

Використані статистичні методи та методи ML

Нижче наведено короткий опис методів МН, які використовувалися у дисертаційному дослідженні. Також було включено окрім PHM [101] її підтипи LSTM [102], GRU, BI-LSTM, які почали привертати значну увагу у сфері прогнозування.

2.5.1 Багатошаровий персептрон (MLP)

Спочатку будується один прихований шар NN. Потім визначається найкраща кількість вхідних вузлів $N = [1, 2, \dots, 5]$ за допомогою 10-кратного процесу валідації, де вхідними даними є спостереження $Y_{t-5}, Y_{t-4}, Y_{t-3}, Y_{t-2}$ та Y_{t-1} для прогнозування часового ряду в точці t , і так для всіх $n - 18$ даних. По-третє, кількість прихованих вузлів дорівнює $2N + 1$ відповідно до практичних рекомендацій [103], спрямованих на зменшення обчислювального часу, необхідного для побудови NN-моделі (кількість прихованих шарів, що використовуються, як правило, має другорядне значення) [104]. Для визначення оптимальних ваг замість стандартного зворотного розповсюдження використовується метод масштабованого спряженого градієнта [105]. Цей метод, який є альтернативою відомому алгоритму Левенберга-Марквардта, виявився кращим у багатьох застосуваннях і вважається більш придатним для оптимізації ваг. Швидкість навчання вибирається між 0,1 і 1, використовуючи випадкові початкові ваги для запуску

процесу навчання з максимум 500 ітерацій. Нарешті, щоб максимізувати гнучкість методу, хоча функція активації прихованого шару є логістичною, для вихідних вузлів використовується лінійна функція. Це має вирішальне значення, оскільки, якщо логістична функція активації виходу використовується для оптимізації трендових часових рядів, вона є обмеженою і приреченою на провал [100]. Крім того, завдяки нелінійним активаційним функціям дані масштабуються від 0 до 1, щоб уникнути обчислювальних проблем, задовольнити вимоги алгоритму та сприяти швидшому навчанню мережі [101].

Після того, як всі прогнози зроблені, прогнози повертаються до початкового масштабу.

Після визначення архітектури оптимальної нейронної мережі було додатково навчено 100 моделей MLP, які були використані для екстраполяції ряду. Середнє, медіана та мода окремих прогнозів були використані як остаточні прогнози. Це було зроблено для того, щоб оцінити можливі переваги комбінації прогнозів, про які широко повідомляється в літературі, особливо у випадку нейронних мереж, які характеризуються великими варіаціями при використанні різних початкових параметрів [106]. Однак, враховуючи, що виграш у точності при об'єднанні декількох прогнозів є незначним, а складність майже подвоюється, ми не наводимо всі результати, оскільки в цьому немає необхідності.

Метод MLP побудовано за допомогою функції `mlp` статистичного пакету RSNNS R [107].




Рисунок 2.5 – Прогнозування АТ за допомогою багатошарового персептрону

Таблиця 2.1.

Метрики помилок багат шарового персептрону

Метрики	Прогнозування 1 крок	Прогнозування 3 кроки	Прогнозування 5 кроків
MAE	0.230189448595047	0.29727451026439666	0.3351688623428345
MAPE	54.808580017089845	63.75174438476562	66.54087677001954
MSE	0.16029949337244034	0.21444786608219146	0.25251813381910326
RMSE	0.27363682389259336	0.33731068193912506	0.3764046519994736

2.5.2 Байєсівська нейронна мережа (BNN)

BNN схожий на метод MLP, але оптимізує параметри мережі відповідно до байєсівської концепції, що означає, що ваги оцінюються з урахуванням апіорного розподілу помилок. Метод побудовано відповідно до пропозицій, наданих у [108] та [109]. Алгоритм Нгуєна та Відроу [110] використовується для призначення початкових ваг, а алгоритм Гаусса-Ньютона - для виконання оптимізації. Подібно до методу MLP, найкраща кількість вхідних вершин $N = [1, 2, \dots, 5]$ визначається за допомогою 10-кратної перевірки, а кількість прихованих вершин дорівнює $2N + 1$. Розглянуто 500 ітерацій, дані лінійно масштабуються.

Метод BNN побудовано за допомогою функції bPHM статистичного пакету bPHM R [111].




Рисунок 2.6 –Прогнозування АТ за допомогою Бейєсовської нейронної мережі

Таблиця 2.2.

Метрики помилок Байєсовської нейронної мережі

Метрики	Прогнозування 1 крок	Прогнозування 3 кроки	Прогнозування 5 кроків
MAE	0.23996027410030366	0.34328516840934753	0.36592585742473605
MAPE	54.95966110229492	78.57954895019532	100.90864410400391
MSE	0.16334840506315232	0.2624185335636139	0.28738179206848147
RMSE	0.27797248065471647	0.38685065031051635	0.41208949089050295

2.5.3 Радіальні базисні функції (RBF)

RBF - це мережа прямого поширення з одним прихованим шаром і схожа на метод MLP. Але замість сигмоїдної функції активації він використовує лінійну комбінацію з n базисних функцій, які є радіально симетричними навколо центру. Таким чином, інформація представляється локально в мережі, що робить метод більш зрозумілим і швидшим в обчисленнях. Як і в попередніх підходах, найкраща кількість вхідних вузлів $N = [1, 2, \dots, 5]$ визначається за допомогою 10-кратної перевірки, а кількість прихованих вузлів автоматично встановлюється рівною $2N + 1$. Розглянуто 500 ітерацій, а дані лінійно масштабуються. Вихідна функція активації є лінійною.

Метод RBF побудовано з використанням функції `rbf` статистичного пакету RSNNS R [107].

2.5.4 Узагальнені регресійні нейронні мережі (GRNN)

Метод GRNN, який також називають оцінкою Надарая-Вотсона або ядерною регресійною оцінкою, реалізується за алгоритмом, запропонованим в [112]. На відміну від попередніх методів, GRNN є непараметричним, і прогнози знаходять шляхом усереднення цільових виходів навчальних точок даних відповідно до їх відстані від спостережень, що надаються кожного разу. Параметр `sigma`, який визначає гладкість підгонки, обирається разом з кількістю вхідних даних N за допомогою 10-кратної валідації. Лінійно масштабовані вхідні дані змінюються від 1 до 5, а сигма - від 0,05 до 1 з кроком 0,05.

Метод GRNN побудовано з використанням функцій вгадування, навчання та згладжування статистичного пакету gRNN R [113].

2.5.5 Регресія К-найближчого сусіда (KNN)

KNN - це непараметричний метод регресії, який базує свої прогнози на мірі подібності, евклідовій відстані між точками, що використовуються для навчання та тестування методу. Таким чином, маючи N вхідних даних, метод вибирає найближчі K точок навчальних даних і встановлює прогноз як середнє значення цільових вихідних значень для цих точок. Параметр K , який визначає гладкість підгонки, знову оптимізується разом з кількістю вхідних даних за допомогою 10-кратної перевірки. Вхідні дані, які лінійно масштабуються, можуть змінюватися від 1 до 5, а K - від 2 до 10.

Метод KNN побудовано з використанням функції KNN статистичного пакету класу R [114].




Рисунок 2.7 – Прогнозування АТ за допомогою регресії К-найближчого сусіда

Таблиця 2.3.

Метрики помилок К-найближчих сусідів

Метрики	Прогнозування 1 крок	Прогнозування 3 кроки	Прогнозування 5 кроків
MAE	0.22718803531252632	0.242290645688932	0.2693614557386084
MAPE	0.825880250358887	0.7921052688943752	0.7293791275665588
MSE	0.15317126688758925	0.16909994288103186	0.19673615230595795
RMSE	0.2624507788401562	0.2758465517695237	0.3021945147028736

2.5.6 Древа рішень

Древа рішень CART (Classification and regression tree) — це метод регресії, заснований на деревоподібному рекурсивному розбитті вхідного простору [115]. Простір, заданий навчальною вибіркою, розбивається на області, які називаються термінальними листям. Потім вводиться послідовність тестів, які застосовуються до вузлів прийняття рішень для того, щоб визначити, до якого листка слід віднести об'єкт на основі наданих вхідних даних. Тести застосовуються послідовно від кореневого вузла до листків, поки не буде прийнято остаточне рішення [116].




Рисунок 2.8 – Прогнозування АТ за допомогою дерев рішень

Таблиця 2.4.

Метрики помилок дерев рішень

Метрики	Прогнозування 1 крок	Прогнозування 3 кроки	Прогнозування 5 кроків
MAE	0.34881012823403623	0.26259677985716096,	0.2335927969128856
MAPE	1.2874204290256246	0.8203641746800283	0.6696430682293664
MSE	0.27630925951039	0.18176697130613997	0.17243016179684353
RMSE	0.39588609789775664	0.2952770940213837	0.25575569704200696

2.5.7 Машина опорних векторів (SVM)

SVR - це процес регресії, що виконується машиною опорних векторів, яка намагається ідентифікувати гіперплощину, що максимізує різницю між двома класами та мінімізує загальну похибку в межах допуску [117]. Для того, щоб побудувати ефективну SVM, також вводиться штраф за складність, який балансує між точністю прогнозування та обчислювальною продуктивністю.

Оскільки в даному дослідженні точність набагато важливіша за складність, прогнози були отримані за допомогою γ -регресійної SVM, яка максимізує межі поля за відповідних умов, щоб уникнути включення викидів, що дозволяє SVM приймати рішення про кількість необхідних опорних векторів. Ядро, яке використовується для навчання і прогнозування, є радіально-базовим, головним чином через його хорошу загальну продуктивність і невелику кількість параметрів, які він вимагає. Згідно з пропозиціями [99], параметр γ встановлюється рівним рівню шуму навчальної вибірки, тоді як вартість порушення обмежень C фіксується на максимальному з цільових вихідних значень, що дорівнює 1. Потім параметр γ оптимізується разом із загальною кількістю входів N , заданих для методу, з використанням 10-кратного процесу валідації. Вхідні дані лінійно масштабуються, як і в попередніх описаних методах.

Метод SVR побудовано з використанням функції SVM статистичного пакету e1071 R [118].




Рисунок 2.9 – Прогнозування АТ за допомогою регресії машини опорних векторів

Таблиця 2.5.

Метрики помилок машини опорних векторів

Метрики	Прогнозування 1 крок	Прогнозування 3 кроки	Прогнозування 5 кроків
MAE	0.3202216938802813	0.28138468610687056	0.2790621829839274
MAPE	0.746176731121398	0.8418758019218755	0.8950136992980421
MSE	0.24311915525289	0.20160997414351647	0.20590586375640604
RMSE	0.3664511187126417	0.3199551797005248	0.31641692837053026

2.5.8 Гаусові процеси (ГП).

Згідно з ГП, кожна цільова змінна може бути пов'язана з однією або декількома нормально розподіленими випадковими величинами, які утворюють багатовимірний нормальний розподіл, що виникає шляхом об'єднання індивідуальних розподілів незалежних змінних [119]. У цьому відношенні гаусові процеси можуть слугувати непараметричним методом регресії, який передбачає апріорний розподіл вхідних змінних, отриманих під час навчання, а потім комбінує їх відповідним чином, використовуючи міру подібності між точками (функцію ядра), щоб передбачити майбутнє значення змінної, яка нас цікавить. У нашому випадку вхідними змінними є минулі спостереження часового ряду, лінійно масштабовані, а їх загальна кількість $N = [1, 2, \dots, 5]$ визначається за допомогою 10-кратного процесу валідації. Ядерна функція, що використовується, є радіально-базисною, а початкова дисперсія шуму та допуск на закінчення були встановлені на рівні 0,001, оскільки, як зазначено в [99], використання тривимірного 10-кратного валідаційного підходу для їх визначення було б надто дорогим з точки зору обчислювальної техніки.

Метод GP побудовано з використанням функції `gausspr` статистичного пакету `kernlab` R [120].

2.5.9 Рекурентна нейронна мережа (PHM)

Рекурентні нейронні мережі (PHM, Recurrent Neural Networks - RNN) — це нейронні мережі для послідовних даних (елементи зв'язані послідовно), тому їх застосовують до часових рядів. Основна ідея рекурентних нейронних мереж полягає у використанні не лише вхідних даних, а й попередніх вихідних даних для створення поточного прогнозу. Однак ці мережі важко навчати і вони можуть забувати дані.

Рекурентна нейронна мережа використовує отриману раніше інформацію для розв'язання задач.

Іноді для розв'язання завдання потрібно переглянути тільки останню інформацію. У випадках, коли розрив між попередньою інформацією і місцем,

у якому вона потрібна, невеликий, РНМ впорається із завданням, однак на практиці РНМ не здатні вирішити це завдання.

Є три популярні та ефективні РНМ: довга короткочасна пам'ять (Long Short Term Memory – LSTM), керований (вентильний) рекурентний блок (Gated Recurrent Unit – GRU) та двонаправлена довга короткочасна пам'ять (Bidirectional Long Short-Term Memory – BI-LSTM). Ці мережі мають змогу зменшити вплив проблеми загасаючого/вибухового градієнта під час навчання рекурентних моделей із використанням Backpropagation Through Time (BPTT) алгоритму на довгих послідовностях.

2.5.9.1. Мережі LSTM

Довга короткострокова пам'ять (long short-term memory – LSTM) — це тип РНМ, який може навчитися довгостроковим залежностям. На відміну від звичайних РНМ, LSTM можуть пам'ятати попередню інформацію протягом тривалого часу.

Архітектура LSTM базується на ключовому компоненті — стані комірки, який являє собою горизонтальний потік інформації у верхній частині моделі. Він виконує роль довготривалого сховища даних, обсяг яких може динамічно змінюватися відповідно до потреб нейронної мережі [121].

Контроль за збереженням і передачею інформації здійснюється через ворота, які функціонують як керуючі механізми. Вони реалізуються за допомогою сигмоїдного шару нейронної мережі та операції покомпонентного множення. Вихідні значення сигмоїдного шару знаходяться в діапазоні від 0 до 1, де 0 означає повне блокування потоку даних, а 1 — повне пропускання. Завдяки цьому механізму модель може ефективно відбирати, які саме фрагменти інформації необхідно зберегти або передати для подальшої обробки.

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (2.6)$$

$$\tilde{C}_t = \tanh(W_C \cdot [h_{t-1}, x_t] + b_C) \quad (2.7)$$

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \quad (2.8)$$

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (2.9)$$

$$h_t = o_t * \tanh(C_t) \quad (2.10)$$

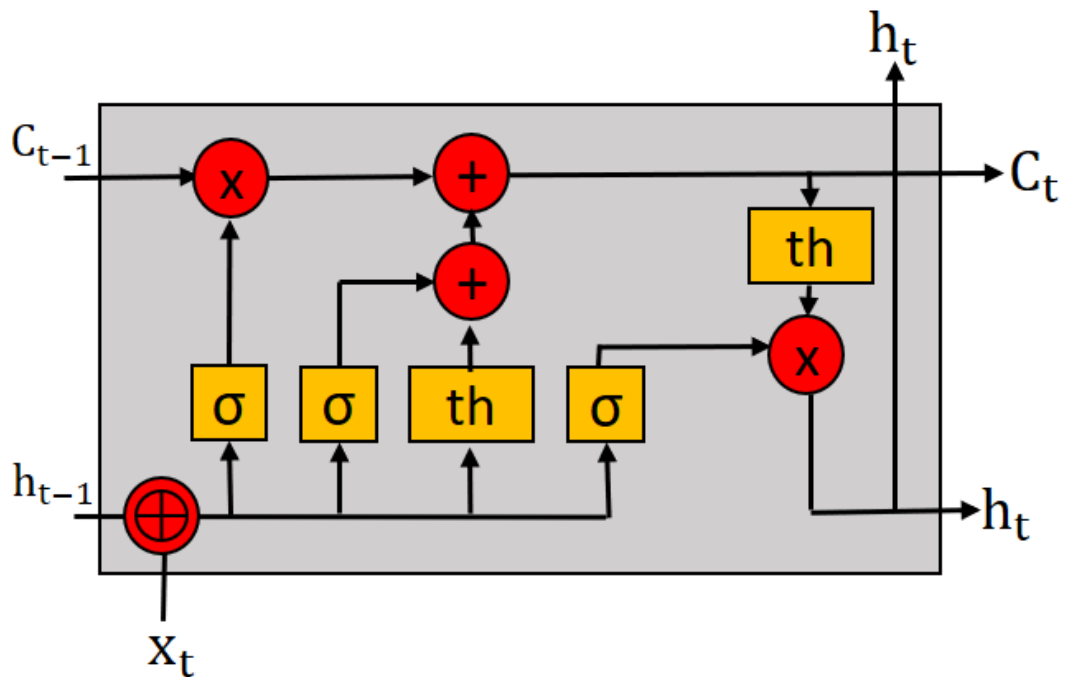


Рисунок 2.10 – Архітектура LSTM

Результати прогнозування артеріального тиску з використанням LSTM наведено на рис. 2.10 та табл. 2.6.




Рисунок 2.11 – Прогнозування АТ за допомогою LSTM

Таблиця 2.6.

Метрики помилок LSTM

Метрики	Прогнозування 1 крок	Прогнозування 3 кроки	Прогнозування 5 кроків
MAE	0.2508718580007553	0.35047129809856414	0.41805645227432253
MAPE	73.90834197998046	108.46131622314454	124.95271148681641
MSE	0.17330400496721268	0.27765710175037384	0.367828780412674
RMSE	0.2914471238851547	0.40076422214508056	0.4800217986106873

2.5.9.2. Мережі GRU

Вентильний рекурентний блок (Gated recurrent unit – GRU) — це тип РНМ, який вирішує проблеми стандартної РНМ, але простіший за будовою ніж LSTM через меншу кількість елементів. У GRU фільтри «забуття» та входу поєднують в один фільтр «оновлення». До того ж, СК поєднується із прихованим станом [122].

У даному нейроні вектор виходів h_t також «виконує» роль вектора контексту, і використовуються наступні блоки:

- Блок оновлення $z_t(x_t, h_{t-1}, W_z)$, що розраховує ваги в діапазоні $(0, 1)$, які застосовуються для розрахунку нового вектора виходів (і, одночасно, контексту) h_t , виходячи з вектора-кандидата \tilde{h}_t та попереднього вектора h_{t-1} ;
- Блок «релевантності» $r_t(x_t, h_{t-1}, W_r)$, що розраховує ваги в діапазоні $(0, 1)$, що визначають «релевантність»/«важливість» значень попереднього вихідного вектора h_{t-1} при розрахунку вектора-кандидата для нового вихідного вектора \tilde{h}_t ;
- Блок розрахунку вектора-кандидата нових виходів $\tilde{h}_t(x_t, h_{t-1}, r_t, W)$;
- Блок розрахунку нового вектора виходів $h_t(h_{t-1}, \tilde{h}_t, z_t)$ як зваженої суми відповідних значень попереднього вектора h_{t-1} і нового вектора-кандидата \tilde{h}_t , де ваги для значень під індексом i вибираються як $1 - z_t[i]$ та $z_t[i]$ відповідно. У цьому нейроні вихідний вектор h_t також «виконує» роль контекстного вектора, і використовуються такі блоки:
- Блок оновлення $c_t(x_t, h_{t-1}, IN_c)$, $c_t(x_t, h_{t-1}; IN_c)$, який обчислює ваги в діапазоні $(0, 1)$, які використовуються для обчислення нового вихідного вектора (і, водночас, контексту) h_t на основі вектора-кандидата h_t і попередній вектор h_{t-1} .
- Блок «Релевантність». $r_t(x_t, h_{t-1}, IN_r)$, який обчислює ваги в діапазоні $(0, 1)$, які визначають «релевантність» / «важливість» значень попереднього вихідного вектора h_{t-1} під час обчислення вектора-кандидата для нового вихідного вектора h_t .

- Блок для розрахунку вектора-кандидата нових виходів $h_t(x_t, h_{t-1}, r_t, IN)$.
- Блок для обчислення нового вихідного вектора $h_t(h_{t-1}, h_t, c_t)$ як зважена сума відповідних значень із попереднього вектора h_{t-1} і новий вектор кандидата h_t , де ваги для значень під індексом i вибираються як $1 - c_t[i]$ і $c_t[i]$ відповідно.

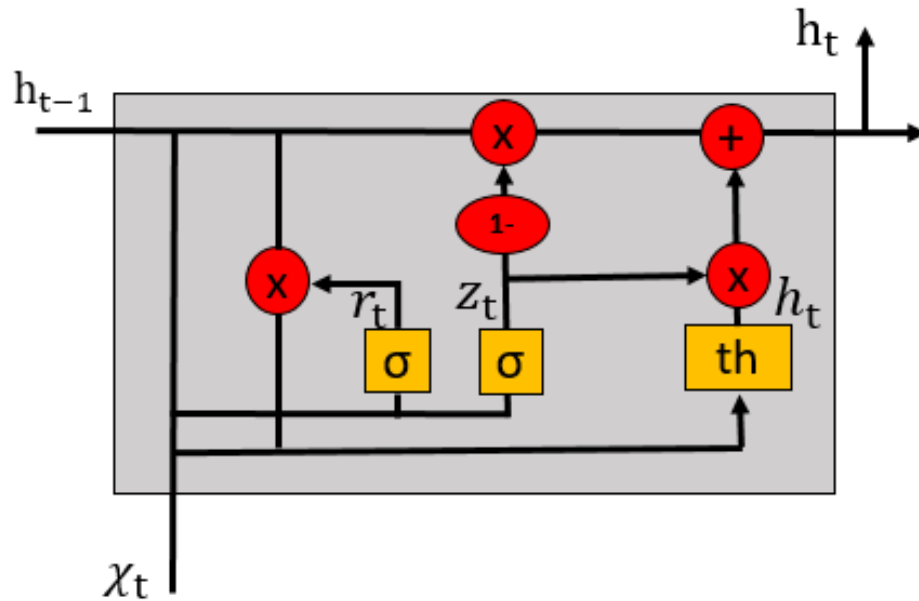


Рисунок 2.12 – Архітектура GRU

$$z_t = \sigma(W_z \cdot [h_{t-1}, x_t]), \quad (2.11)$$

$$r_t = \sigma(W_r \cdot [h_{t-1}, x_t]), \quad (2.12)$$

$$h_t = \tanh(W \cdot [r_t \cdot h_{t-1}, x_t]), \quad (2.13)$$

$$h_t = (1 - z_t) \cdot h_{t-1} + z_t \cdot h_t. \quad (2.14)$$

Результати прогнозування артеріального тиску з використанням GRU наведено на рис. 2.11 та табл. 2.7.




Рисунок 2.13 – Прогнозування АТ за допомогою GRU

Таблиця 2.7.

Метрики помилок GRU

Метрики	Прогнозування 1 крок	Прогнозування 3 кроки	Прогнозування 5 кроків
MAE	0.12439206779003144	0.1911632661819458	0.225482360124588
MAPE	57.78880523681641	88.95266064453125	104.5654214477539
MSE	0.05029731035232544	0.11382382559776306	0.16329558253288268
RMSE	0.16363367974758147	0.2388224844932556	0.2835762655735016

2.5.9.3. Мережі BI-LSTM

$X_t = [x_1, x_2, \dots, x_t]$ - це вхідні характеристики, які отримані з сигналів, $Y_t = [y_1, y_2, \dots, y_t]$ позначають цільове значення. Умовна ймовірність $p(Y_t|X_t)$ розкладається на множники

$$p(Y_T|X_T) = \prod_{t=1}^T p(y_t|h_t) \quad (2.15)$$

де h_t можна інтерпретувати як прихований стан динамічної системи АТ, і він генерується з попереднього прихованого стану h_{t-1} і поточний вхід x_t як:

$$h_t = f(h_{t-1}, x_t) \quad (2.16)$$

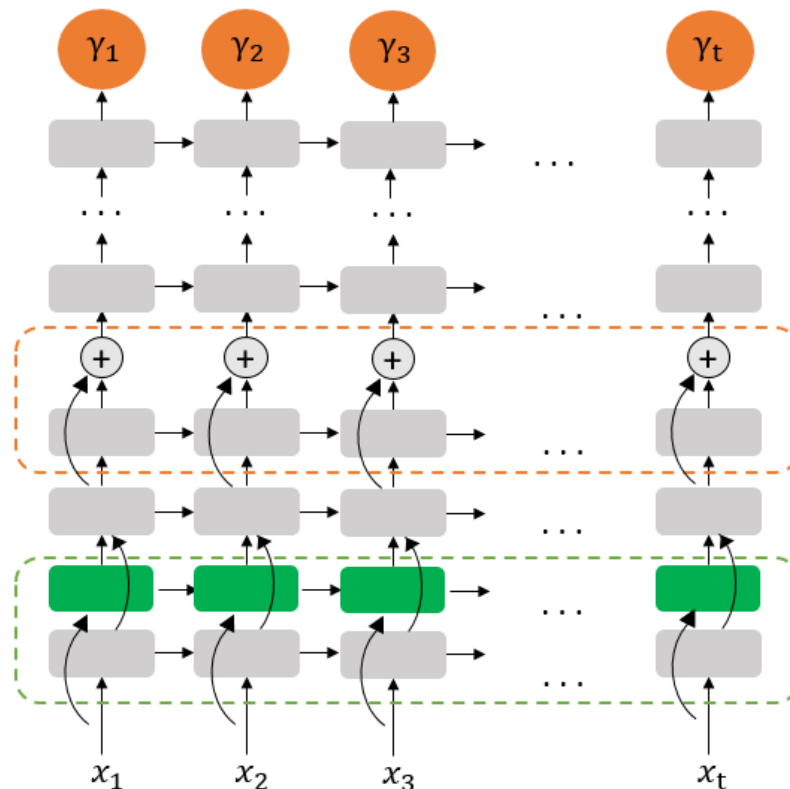


Рисунок 2.14 – Архітектура BI-LSTM. Зелена пунктирна рамка внизу — це двонаправлений шар LSTM, що складається з прямого (помаранчевого) і зворотного (зелений) LSTM. Помаранчева пунктирна рамка образує LSTM шар із залишковими зв'язками.

Звичайні LSTM використовують h_t для збору інформації з минулої історії x_1, \dots, x_{t-1} та поточного входу x_t . Для того, щоб отримати доступ до більш масштабного часового контексту вхідної послідовності, можна також включити інформацію про найближче майбутнє x_{t+1}, \dots, x_T для інформування подальшого процесу моделювання. Двонаправлені РНМ можуть реалізувати цю функцію, обробляючи даних як у прямому, так і в зворотному напрямках за допомогою двох окремими прихованими шарами, які потім зливаються в один вихідний шар, які потім зливаються в один вихідний шар [123]. Як показано в нижній частині Рисунку 2.13, BI-LSTM обчислює прямий прихований стан h_t^f зворотний прихований стан h_t^b і кінцевий вихід h_t за такими рівняннями:

$$h_t^f = H(W_{hh}^f h_{t-1}^f + W_{xh}^f x_t + b_f) \quad (2.17)$$

$$h_t^b = H(W_{hh}^b h_{t+1}^b + W_{xh}^b x_t + b_b) \quad (2.18)$$

$$h_t = W^f h_t^f + W_{xh}^f x_t W^b h_t^b + b_h \quad (2.19)$$

Результати прогнозування артеріального тиску з використанням BI-LSTM наведено на рис. 2.14. та табл. 2.8.




Рисунок 2.15 – Прогнозування АТ за допомогою BI-LSTM

Таблиця 2.8.

Метрики помилок BI-LSTM

Метрики	Прогнозування 1 крок	Прогнозування 3 кроки	Прогнозування 5 кроків
MAE	0.1528659814596176	0.25482955026626586	0.24249140977859496
MAPE	76.09858154296874	127.76467236328125	112.48310028076172
MSE	0.0752084830403328	0.20251152861118316	0.1814575946331024
RMSE	0.19640794932842254	0.31549927043914794	0.2984147226810455

На рисунку 2.16 зображено порівняння архітектур BI-LSTM, LSTM, GRU.

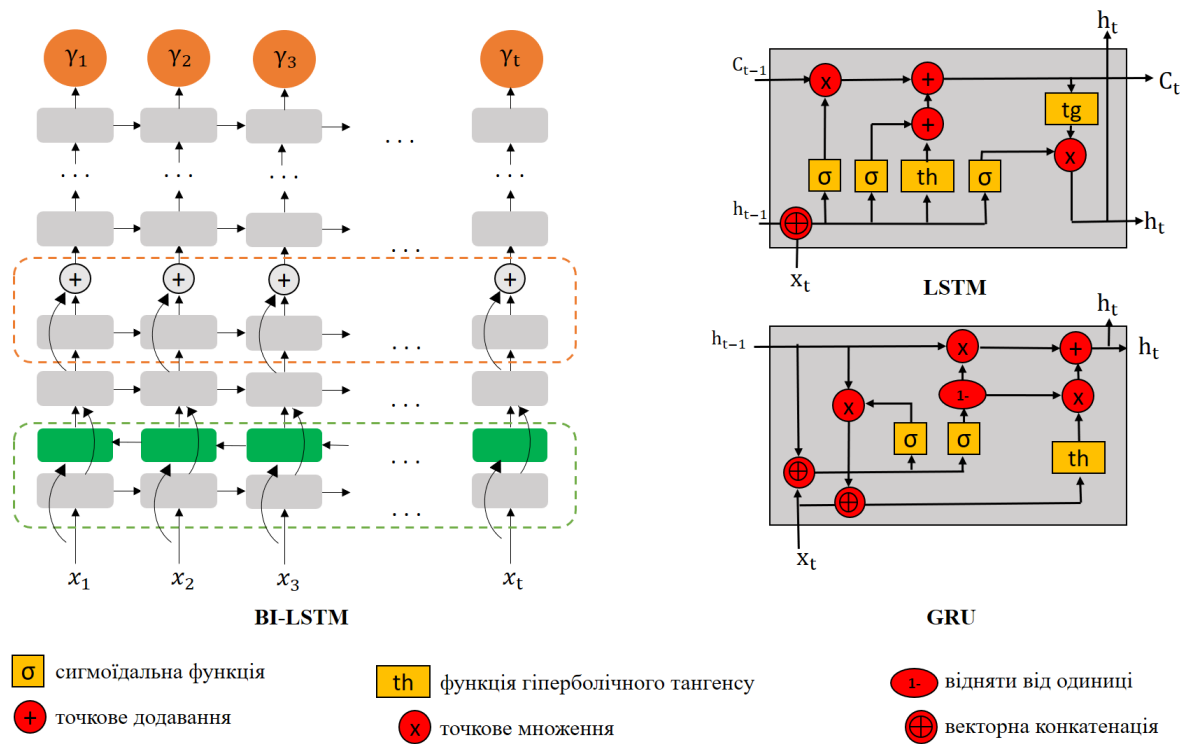


Рисунок 2.16 – Порівняння архітектур BI-LSTM, LSTM, GRU

Таблиця 2.9

Порівняння архітектур PHM, LSTM, GRU, BI-LSTM

Характеристика	PHM	LSTM	GRU	Bi-LSTM
Архітектура	Проста	Складна з комірками пам'яті	Спрощена версія LSTM	Два LSTM (вперед і назад)

Характеристика	PHM	LSTM	GRU	Bi-LSTM
Гейти	Немає	Забуваючий, введення, вихід	Оновлення, скидання	Як у LSTM
Пам'ять	Короткотривала	Довготривала	Схожа на LSTM	Довготривала
Контекст	Лише попередній	Лише попередній	Лише попередній	Попередній і наступний
Проблема з градієнтом	Вразливий до затухання	Вирішує проблему	Також вирішує проблему	Як у LSTM
Швидкість навчання	Швидка	Повільніша через складність	Швидша за LSTM	Повільніша через подвійну обробку

2.5.10. Згорткові нейронні мережі

2.5.10.1 Informer

Для вирішення завдання на проблемі LSTF, було запропоновано Informer з архітектурою кодер-декодер. Огляд моделі Informer зображено на рис.(2.17).

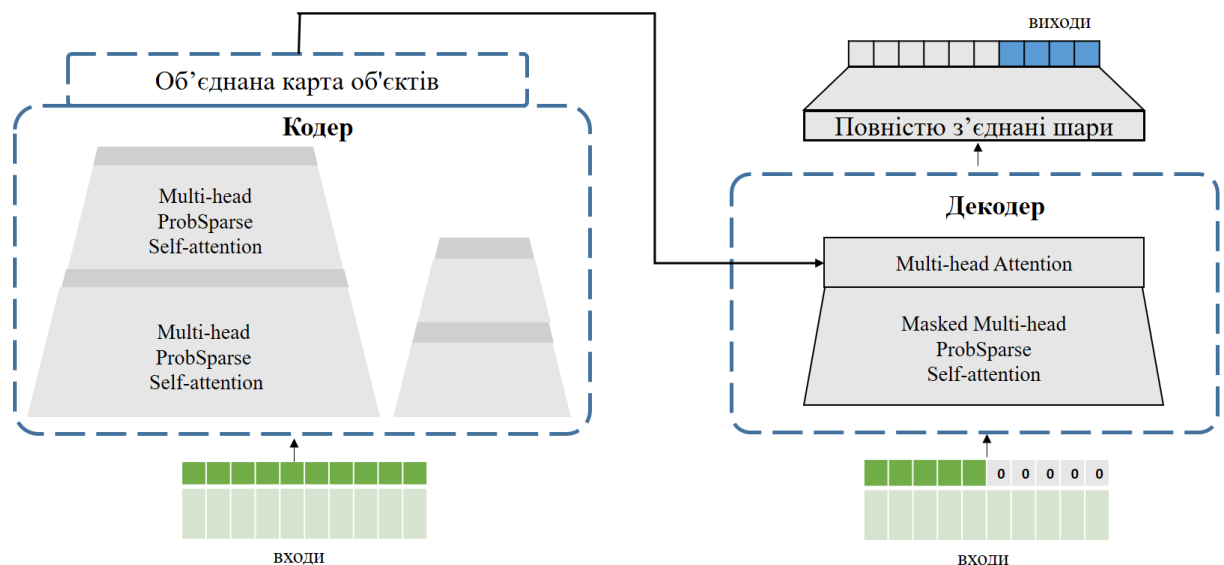


Рисунок 2.17 – Огляд моделі Informer

Ефективний механізм самоуваги

Механізм самоуваги ґрунтується на вхідних даних у вигляді трьох компонентів: запит(query), ключ(key) та значення(value) [124].

Вимірювання розрідженості запитів

На основі цієї метрики ProbSparse Self-attention було розроблено механізм ProbSparse Self-attention, що оптимізує обчислювальні ресурси, зосереджуючись лише на u найважливіших запитах для кожного ключа.

Кодер створений для вилучення стійких довготривалих залежностей зі значно довгих вхідних послідовностей. У процесі роботи, після подання даних у вигляді t -ї послідовності \mathcal{X}^t , останню формують у матрицю $X_{en}^t \in \mathbb{R}^{L_x \times d_{model}}$. Схема роботи кодера наведена на рис.(2.18).

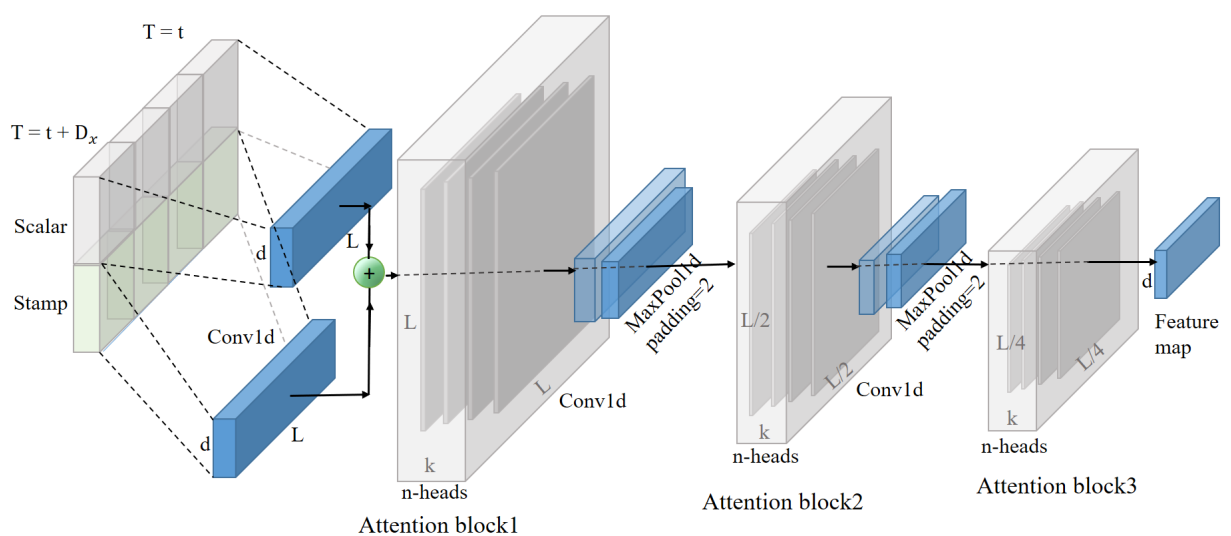


Рисунок 2.18 – Схема роботи кодера. (1) Горизонтальний стек символізує окрему складову кодера на рис.(2.18). (2) Основний стек приймає всю вхідну послідовність. Далі наступний стек обробляє половину цієї послідовності, а інші стеки формуються ідентичним каскадом. (3) Сірі шари представляють матриці точкових добутків і реалізують каскадне зменшення через дистилляцію самоуваги на кожному рівні. (4) З'єднання карт ознак усіх стеків подається на вихід кодера.

Механізм дистилляції самоуваги ґрунтується на властивості ProbSparse, за якою ознаки кодера часто мають надлишкові комбінації цінностей V . Застосовуючи дистилляцію, виділяються найбільш важливі комбінації з ознаками, що домінують, утворюючи сфокусовану карту самоуваги для наступного шару. Це дозволяє суттєво зменшити часовий розмір вхідних

даних, що добре ілюструється у матриці вагових коефіцієнтів багатоголових уваг(сірі квадрати) на рис.(2.18).

На рисунку 2.17 представлено стандартну архітектуру декодера [124]. Вона складається зі стеку двох ідентичних шарів багатоголової уваги. У нашому підході застосовується генеративний висновок задля пом'якшення зниження продуктивності під час довготривалого прогнозування.

Generative Inference

Стартовий маркер ефективно застосовується у «динамічному декодуванні» НЛП [125], що дозволяє адаптувати цей підхід до генеративної моделі.

Для навчання моделі було використано функцію втрат середньоквадратичної помилки (MSE), яка розраховується відносно цільових послідовностей. Градієнти помилок поширюються з виходів декодера назад через усю модель, забезпечуючи ефективне коригування її параметрів.

2.5.10.2 Autoformer

Прогнозування часових рядів спрямоване на визначення найбільш ймовірного майбутнього ряду з довжиною O , використовуючи відомі дані минулого — ряд довжини I — що описується як підхід *input – I – predict – O*. Зокрема, завдання довгострокового прогнозування зосереджено на прогнозах значних часових інтервалів у майбутньому, тобто при збільшеній довжині O . Як було зазначено раніше, це завдання ускладнюється через потребу у врахуванні складних часових закономірностей та обмежень, пов'язаних із обчислювальною ефективністю й оптимальним використанням інформації. Для вирішення цих викликів у дослідженні запропоновано інтеграцію блоку декомпозиції до складу моделей глибокого навчання, а також архітектуру Autoformer, яка базується на принципах декомпозиції. Окрім цього, запропоновано механізм автокореляції для аналізу залежностей на основі періодичних компонентів та агрегації схожих підсерій, що походять з базових періодів.

Архітектура декомпозиції

Було запропоновано модернізацію моделі Transformer [124], адаптуючи її до архітектури глибокої декомпозиції (рис. 2.18). Модель містить кілька ключових компонентів, зокрема внутрішній блок декомпозиції часових рядів, механізм автокореляції, а також спеціалізовані модулі кодера та декодера.

Блок декомпозиції часових рядів

Для моделювання складних часових закономірностей у задачах довгострокового прогнозування було інтегровано концепцію декомпозиції часових рядів [126,127]. Ця методика дозволяє розділити часовий ряд на дві взаємопов'язані частини: трендово-циклічну компоненту, яка відображає довгострокову еволюцію даних, та сезонну компоненту, що представляє короткострокові коливання. Однак пряме застосування такої декомпозиції до майбутніх рядів ускладнене через відсутність інформації про майбутні точки даних. Щоб вирішити цю проблему, було впроваджено внутрішній блок декомпозиції часових рядів як складову моделі Autoformer (див. Рисунок 2.19). Цей блок поступово виділяє довгостроковий стаціонарний тренд із прогнозованих прихованих проміжних змінних. Зокрема, для згладжування короткострокових коливань і виділення стабільних довгострокових трендів використовується ковзна середня. Для вхідного ряду $\mathcal{X} \in \mathbb{R}^{L \times d}$, де L позначає довжину ряду, алгоритм декомпозиції виглядає наступним чином:

$$\mathcal{X}_t = AvgPool(Padding(\mathcal{X})) \quad (2.20)$$

$$\mathcal{X}_s = \mathcal{X} - \mathcal{X}_t \quad (2.21)$$

де $\mathcal{X}_s, \mathcal{X}_t \in \mathbb{R}^{L \times d}$ репрезентують сезонну та трендово-циклічну частини відповідно. У цій формулі $AvgPool(\cdot)$ виконує операцію ковзного усереднення з використанням доповнення $Padding$, що дозволяє зберігати початкову довжину ряду. У сукупності описаний процес позначається як $\mathcal{X}_s, \mathcal{X}_t = SeriesDecomp(\mathcal{X})$ і становить основний функціональний модуль архітектури нашої моделі.

Вхідні дані моделі

Вхідними даними для кодерної частини слугують минулі I часових кроків $\mathcal{X}_{en} \in \mathbb{R}^{I \times d}$. Як і в загальній архітектурі декомпозиції (див. Рисунок 2.19), вхід до декодера Autoformer включає як сезонну частину $\mathcal{X}_{des} \in \mathbb{R}^{(\frac{I}{2}+O) \times d}$, так і трендово-циклічну частину $\mathcal{X}_{det} \in \mathbb{R}^{(\frac{I}{2}+O) \times d}$, які підлягають уточненню. Ініціалізація цих двох компонент складається з інформації про режими другої половини вхідного ряду \mathcal{X}_{en} довжиною $I/2$ та заповнювачів довжиною O , які складаються зі скалярів. Формалізація цього процесу виглядає наступним чином:

$$\mathcal{X}_{ens}, \mathcal{X}_{ent} = \text{SeriesDecomp}(\mathcal{X}_{en \frac{I}{2}/I}) \quad (2.22)$$

$$\mathcal{X}_{des} = \text{Concat}(\mathcal{X}_{ens}, \mathcal{X}_0) \quad (2.23)$$

$$\mathcal{X}_{det} = \text{Concat}(\mathcal{X}_{ent}, \mathcal{X}_{Mean}) \quad (2.24)$$

де $\mathcal{X}_{ens}, \mathcal{X}_{ent} \in \mathbb{R}^{\frac{I}{2} \times d}$ позначають сезонну і трендово-циклічну компоненти ряду \mathcal{X}_{en} відповідно, а $\mathcal{X}_{Mean} \in \mathbb{R}^{O \times d}$ є значенням середнього \mathcal{X}_{en} або нульового заповнення.

Кодер

Як демонструється на рисунку 2.19, кодер побудований для моделювання сезонних особливостей даних. На кодері записана інформація про минулі сезонні компоненти, яка використовується як перехресна інформація, що допомагає декодеру вдосконалювати результати прогнозу. Припустимо, що кодер складається з N шарів. Загальне рівняння для l -го шару кодера описується як:

$$\mathcal{X}_{en}^l = \text{Encoder}(\mathcal{X}_{en}^{l-1}) \quad (2.25)$$

Деталізація виглядає наступним чином:

$$\mathcal{S}_{en, -}^{l,1} = \text{SeriesDecomp}(\text{Auto} - \text{Correlation}(\mathcal{X}_{en}^{l-1}) + \mathcal{X}_{en}^{l-1}) \quad (2.26)$$

$$\mathcal{S}_{en, -}^{l,2} = \text{SeriesDecomp}(\text{FeedForward}(\mathcal{S}_{en}^{l,1}) + \mathcal{S}_{en}^{l,1}), \quad (2.27)$$

Тут « $-$ » позначає усунену трендову частину. Вихід l -го шару кодера визначається як $\mathcal{X}_{en}^l = \mathcal{S}_{en, -}^{l,2}$, де $l \in \{1, \dots, N\}$, а вхідний шар \mathcal{X}_{en}^0 – це вбудоване

\mathcal{X}_{en} . Позначення $\mathcal{S}_{en}^{l,i}, i \in \{1,2\}$ відображають сезонні компоненти, отримані після застосування блоку розкладання на i -му етапі в l -му шарі. У наступному розділі буде детальніше описана функція $\text{Auto-Correlation}(\cdot)$, яка може замінити стандартну самокореляцію.

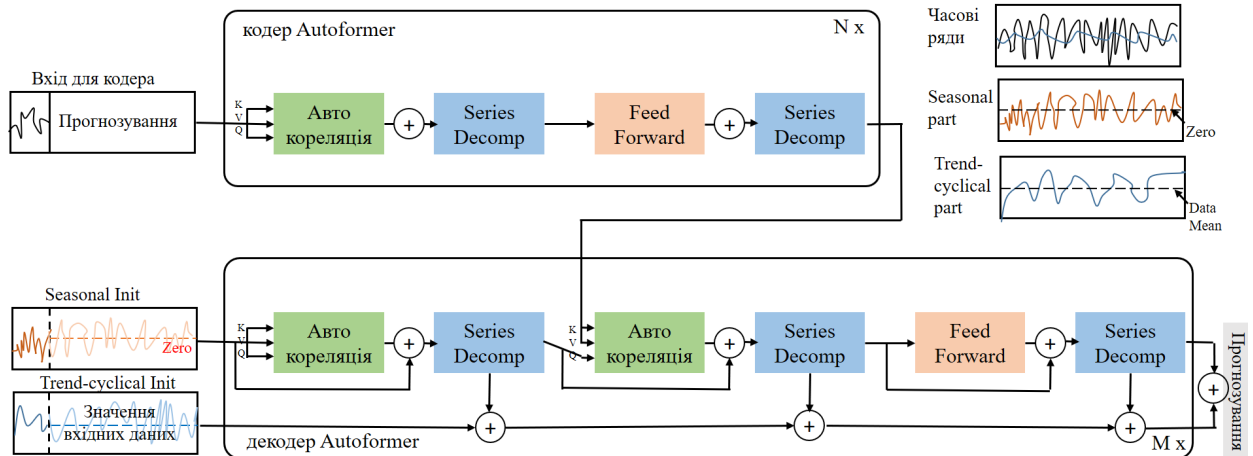


Рисунок 2.19 – Архітектура автоформатора. Кодер працює на усунення довгострокових трендових і циклічних компонент за допомогою блоків серійної декомпозиції (позначені синіми блоками) і концентрується на моделюванні сезонних візерунків.

Декодер

Декодер, у свою чергу, поступово відновлює трендову частину з прихованих змінних. Крім того, інформація про сезонність з кодера використовується через механізм автокореляції між кодером та декодером (зображений зеленим центральним блоком декодера). Декодер. Декодер поділяється на дві основні складові: структура для накопичення трендово-циклічних компонентів та механізм автокореляції для моделювання сезонних компонентів (рис. 2.19). Кожен шар декодера використовує як внутрішню автокореляцію, так і автокореляцію між кодером та декодером для уточнення результатів прогнозування, а також для врахування минулої сезонної інформації. Важливо зазначити, що модель вилучає потенційний тренд із проміжних прихованих змінних під час процесу декодування. Це дозволяє автоформатору поступово вдосконалювати прогноз тренду і ефективно

фільтрувати перешкоджувальну інформацію, щоб знаходити періодичні залежності через механізм автокореляції.

Механізм автокореляції

На основі схеми, представленої на рис. 2.20, було запропоновано механізм автокореляції з послідовними зв'язками для посилення використання інформації про залежності всередині даних. Автокореляція дозволяє виявляти періодичні залежності шляхом розрахунку автокореляції часових серій і об'єднання подібних підсерій через агрегацію часових затримок.

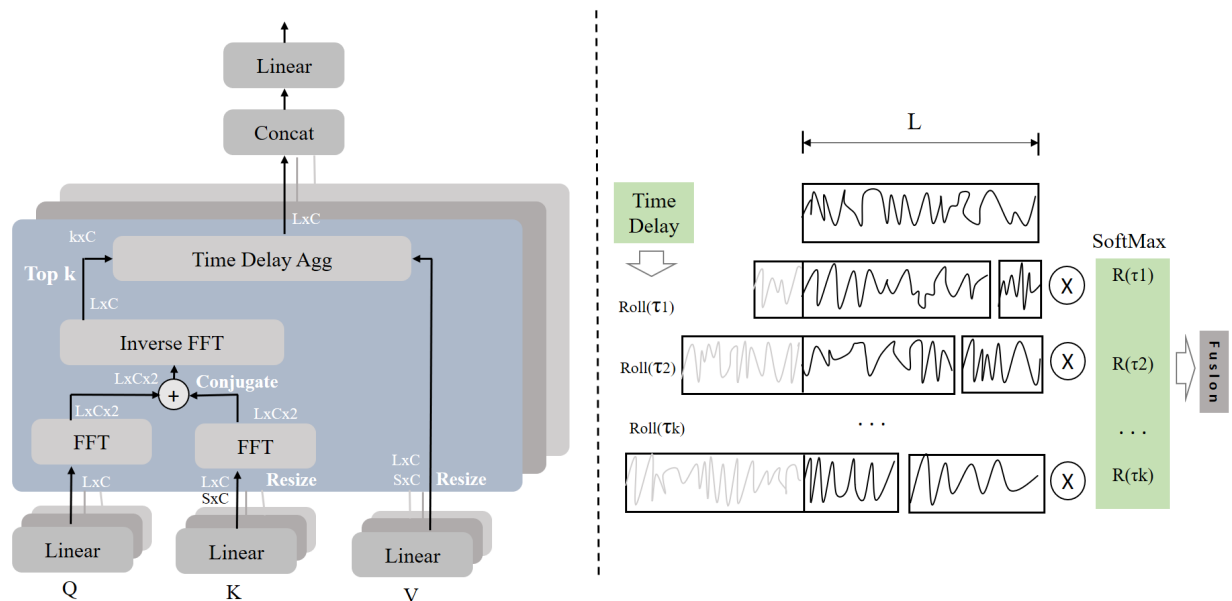


Рисунок 2.20 – Ліворуч процес обчислення автокореляції, а праворуч — механізм агрегації часових затримок.

2.5.10.3 Pyraformer

В мережі Pyraformer спершу спостережувані дані, коваріанти та позиційні характеристики окремо вбудовуються в модель, після чого вони сумуються, подібно до реалізації в Informer [128]. Далі за допомогою модуля побудови грубих масштабів (CSCM) створюється С-арне дерево з різною роздільністю, де вузли грубих масштабів акумулюють інформацію С-вузлів більш дрібного масштабу. Для моделювання часових залежностей у межах різних діапазонів впроваджується модуль пірамідальної уваги (РАМ), в якому передачу інформації реалізовано через механізм уваги в межах пірамідального

графу. Залежно від конкретної задачі прогнозування, застосовуються відповідні мережеві архітектури для отримання фінального результату.

Модуль пірамідальної уваги (РАМ)

Основою Pyraformer є модуль пірамідальної уваги (РАМ). Цей модуль використовує пірамідальний граф для описання часових залежностей у рядах, реалізуючи їх у мультироздільній структурі. Такий підхід показав свою ефективність у моделюванні довготривалих взаємодій у сферах комп'ютерного зору [129,130] і статистичної обробки сигналів [131,132]. Конструкцію пірамідального графу можна умовно поділити на дві складові: міжмасштабні та внутрішньомасштабні зв'язки. Міжмасштабні зв'язки формують С-арне дерево, де кожен вузол-батько має С нащадків. Наприклад, якщо для найдрібнішого масштабу пірамідального графу використовувати погодинні спостереження початкового часового ряду, то вузли на більш грубих масштабах можуть представляти щоденні, тижневі чи місячні характеристики. У результаті пірамідальний граф забезпечує багатороздільне представлення вихідного часового ряду. На більш грубих масштабах легше відобразити довготермінові залежності, наприклад місячні періодичності, шляхом з'єднання сусідніх вузлів за допомогою внутрішньомасштабних зв'язків. Пірамідальний граф Pyraformer дозволяє скоротити обчислювальні витрати до $\mathcal{O}(L)$, не збільшуючи складності максимального шляху передачі сигналу моделі.

Основний механізм уваги. Нехай X і Y відповідно позначають вхід і вихід однієї головки уваги. Для аналізу різноманітних часових шаблонів можна впровадити кілька головок. Спершу X перетворюється в три окремі матриці: запит $Q = XW_Q$, ключ $K = XW_K$ та значення $V = XW_V$, де $W_Q, W_K, W_V \in \mathbb{R}^{L \times D_K}$. Для q_i , рядка i в Q , він взаємодіє з усіма рядками в K . Таким чином, вихід y_i записується як:

$$y_i = \sum_{\ell=1}^L \frac{\exp(q_i \mathbf{k}_{\ell}^T / \sqrt{D_K}) v_{\ell}}{\sum_{\ell=1}^L \exp(q_i \mathbf{k}_{\ell}^T / \sqrt{D_K})} \quad (2.28)$$

Отримані покращення роблять модель придатною для аналізу довготривалих часових рядів, які зазвичай є корисними для підвищення точності прогнозування через більший обсяг інформації про залежності на далекі проміжки.

Будівельний модуль збільшеного масштабу (CSCM)

Основна мета CSCM полягає у створенні вузлів на грубіших масштабах пірамідального графа, що сприяє оптимізації обміну інформацією між вузлами через RAM. Для цього вузли формуються поступово, від найтоншого до найгрубішого масштабу, шляхом виконання згорток на кореляційних зв'язках дочірніх вузлів $\mathbb{C}_\ell^{(s)}$. Кілька згорткових шарів із ядром розміру C та кроком C застосовуються до часової послідовності, перетворюючи її в нову послідовність довжиною $L/C^{(s)}$ на кожному масштабі s . Таким чином, на основі цих послідовностей у різних масштабах формується C-арне дерево. Перед подачею до RAM ці послідовності конкатенуються по порядку: від тонких масштабів до грубих. Для оптимізації параметрів і зменшення обчислювальної складності розмірність кожного вузла знижується через повністю зв'язний шар перед згорткою і відновлюється після неї. Такий підхід дозволяє суттєво зменшити кількість параметрів модуля, а також знижує ризики перенавчання моделі.

Модуль прогнозування

Для виконання однокрокового прогнозування додається маркер кінця (заданий як $z_{t+1} = 0$) до історичної послідовності $z_{t-L+1:t}$, після чого ця послідовність подається до шару вбудовування. Коли RAM закодує цю послідовність, ознаки, отримані від останніх вузлів на кожному рівні пірамідального графа, об'єднуються та подаються у повністю зв'язний шар для отримання прогнозу.

Багатокрокове прогнозування реалізується за допомогою двох можливих підходів. Перший метод продовжує роботу модуля однокрокового прогнозування, але зіставляє останні вузли кожного масштабу з усіма M

майбутніми часовими кроками через пакет обчислень. Другий підхід використовує декодер із двома рівнями повної уваги. Аналогічно до підходу в Transformer [124], майбутні M часових кроків спочатку замінюються на 0 і вбудовуються таким самим методом, як і історичні дані. Ця інформація разом із коваріаціями та позиційним вбудовуванням формує «маркер прогнозу» F_p . На першому рівні уваги маркери прогнозу F_p використовуються як запити, а вихід кодера F_e (всі вузли РАМ) виступає ключем і значенням, що створює проміжний результат F_{d1} . Другий рівень приймає F_{d1} як запит, а комбінацію F_{d1} і F_e — як ключ і значення для обчислень. Історичні дані F_e залишаються ключовими й передаються напряду до обох рівнів уваги, адже ця інформація є вирішальною для точності довготермінового прогнозування. Кінцевий результат прогнозу генерується через повністю зв'язний шар, із використанням розмірності каналів. Обидва підходи забезпечують одночасний вихід усіх прогнозованих значень, що дозволяє уникнути накопичення помилок, характерного для авторегресійного декодера в Transformer архітектурах.

2.5.10.4 TimesNet

Враховуючи багатоперіодичність у часових рядах, використовується TimesNet із модульною архітектурою для ефективного виявлення часових патернів, характерних для різних періодів. Для кожного з таких періодів розроблено компонент TimesBlock, який є частиною TimesNet. Він дає змогу перетворювати одновимірний часовий ряд у двовимірний простір, спрощуючи моделювання як внутрішньоперіодичних, так і міжперіодичних варіацій за рахунок застосування компактної та ефективної параметричної структури.

Перетворення одновимірних варіацій у двовимірні

Кожна точка часу відображає два типи часових варіацій: внутрішньоперіодичні (між сусідніми часовими точками) та міжперіодичні (з однаковою фазою у різних періодах). Проте оригінальна 1D-структура часових рядів здатна представляти лише варіації між сусідніми точками. Щоб усунути цей недолік, було застосовано двовимірну структуру, яка дозволяє явно

моделювати варіації як всередині одного періоду, так і між періодами. Це підвищує здатність до навчання представлення і посилює переваги в загальній ефективності.

Завдяки виявленню періодичних властивостей одновимірний часовий ряд можна перетворити на структуровані двовимірні тензори, які зручно опрацьовувати за допомогою двовимірних ядер. Використовуючи цей підхід для всієї множини різновидів часових рядів, стає можливим розширити наведений процес і на багатовимірні часові ряди.

Варто зауважити, що таке перетворення породжує два типи локалізацій у змінених двовимірних тензорах: це локалізації між сусідніми часовими точками (так звані стовпчики, які характеризують внутрішньоперіодичні варіації) та локалізації між послідовними періодами (рядки, які відображають міжперіодичні варіації). Отже, за допомогою даних двовимірних структур часові варіації можна ефективно обробляти.

Часовий блок

Концепція блоку TimesBlock реалізується за залишковим принципом відповідно до підходу, описаного в роботі [133].

Операція таймблоку для кожного шару складається з двох ключових етапів: корекції часових двовимірних змін та адаптивного об'єднання репрезентацій, отриманих на основі різних періодів.

Захоплення часових 2D-змін

На підставі визначених довжин періодів виконується перетворення одномірного часового ряду у двовимірний простір, що забезпечує отримання набору 2D-тензорів. Цей набір у подальшому використовується для створення інформативних представлень через параметрично-ефективний початковий блок.

Після етапу трансформації даний тензор обробляється за допомогою параметрично ефективного початкового блоку, реалізованого як Inception(\cdot). Цей блок містить багатомасштабні двовимірні ядра та вважається одним із найпоширеніших базових компонентів у задачах комп'ютерного зору.

Адаптивна агрегація

На заключному етапі проводиться адаптивна агрегація. Завдання полягає в інтеграції k різних одномірних представлень для передачі на наступний шар. В роботі [134] ідеї автокореляції використовують амплітуди A для визначення важливості обраних частот та періодів, що своєю чергою задає значимість кожного перетвореного 2D тензора.

Так як внутрішньо- та міжперіодичні варіації вже враховані у структурованих 2D тензорах, TimesBlock здатний повністю охоплювати багатомасштабні часові 2D закономірності. Це дозволяє TimesNet досягати більш ефективного навчання представлень, ніж при роботі лише з одномірними часовими рядами.

Методологія, що передбачає перетворення одномірних часових рядів у двовимірні часові варіації, дозволяє інтегрувати різноманітні архітектури комп'ютерного зору для заміни базового блоку навчання репрезентацій. До таких архітектур належать загальноновживані моделі ResNet [133] і ResNeXt [135], прогресивні ConvNeXt [136], а також моделі, орієнтовані на механізми уваги [137]. Застосування цього підходу сприяє синергії між одномірними часовими рядами і швидко зростаючими 2D-комп'ютерними візуальними основами, що дозволяє аналізу часових рядів отримувати вигоди від досягнень у сфері комп'ютерного зору. Зрештою, потужніші 2D-архітектури для навчання репрезентацій демонструють підвищену ефективність.

2.5.11. Побудова гібридних нейронних для розв'язання задачі прогнозування артеріального тиску

Перші підходи до прогнозування часових рядів базувалися здебільшого на статистичних методах, зокрема регресійному аналізі [138-140]. Ці підходи демонстрували високу ефективність у роботі з даними, що мають лінійні залежності. Однак для обробки нелінійних даних було створено моделі штучного інтелекту, серед яких особливе місце займають нейронні мережі мережі [141-143]. Останнім часом з'явилися гібридні методи, які об'єднують

можливості статистичного аналізу та глибокого навчання, що дозволяє досягати більш точних прогнозів [144-146]. Одним із ключових етапів застосування гібридних методів є попередня обробка даних, яка передбачає розподіл інформації на окремі компоненти [147]. Для цього широко використовуються [148-150] функції типу вейвлет-перетворення, як-от дискретне вейвлет-перетворення (DWT), яке дає змогу розділити дані на лінійну та нелінійну складові. Це дозволяє підвищити точність моделювання завдяки врахуванню особливостей різних компонентів. Для оцінки якості прогнозування зазвичай застосовуються метрики, що забезпечують об'єктивний аналіз результатів. Найпоширенішими серед них є середньоквадратична похибка (RMSE) та середня абсолютна відсоткова похибка (MAPE), які визначають відхилення отриманих значень від реальних даних.

2.5.11.1. Гібридні підходи, що поєднують ARIMA та BPNN або GRNN

Yu та колеги [151] запропонували підхід для прогнозування продажів одягу, спрямований на оптимізацію процесу планування для виробників та продавців цього сектору. Вони вважають, що дані про продажі мають одночасно лінійні і нелінійні компоненти, через що традиційні методи прогнозування є недостатньо ефективними у їх застосуванні до таких даних. Найкращі результати для лінійного фактору вони досягли за допомогою ARIMA (RMSE: 27,684), у той час як для нелінійної складової найвищу точність продемонструвала BPNN (RMSE: 15,503). Запропонована гібридна модель ARIMA-BPNN виявилася найбільш успішною, із найменшою похибкою (RMSE: 12,543) [151]. Hadwan та інші представили універсальний підхід до прогнозування часових рядів [152], який включає три моделі прогнозування: ARIMA, нейронну мережу зі зворотним поширенням (BPNN) з адаптивними параметрами нахилу й імпульсу, а також гібридну модель ARIMA-BPNN. Науковці протестували ці моделі на двох вибірках даних: перша стосувалася прогнозування індексу споживчих цін (ІСЦ), а друга — кількості хворих на рак у провінції Ібб, Ємен. Для оцінювання точності

використовували метрики середньоквадратичної похибки (RMSE), середньої абсолютної похибки (MAE) та середньої абсолютної похибки у відсотках (MAPE). Зокрема, в аналізі набору даних про рак найкращі результати показала гібридна модель ARIMA-BPNN із RMSE 0,453, [152] порівняно з 1,252 для ARIMA та 0,896 для BPNN. Нова розробили метод прогнозування, спрямований на оцінку валового внутрішнього продукту (ВВП), що є важливим макроекономічним показником економічного стану країни чи регіону [153]. Науковці наголосили, що більшість наявних методів прогнозування ВВП орієнтовані виключно на лінійний аналіз. Їхній гібридний підхід об'єднує моделі ARIMA та BPNN. Спочатку прогнозовані значення окремих моделей були зважені й усереднені для отримання показників лінійної частини моделі; далі здійснювалось моделювання нелінійних залишків за допомогою BPNN та їх інтеграція з лінійними прогнозами. Як результат, була досягнута вища точність прогнозування: для ARIMA MAPE дорівнювало 2,80, для BPNN — 3,70, а для запропонованої гібридної моделі — 1,88 [153]. Wang та інші [154] дослідили можливість використання прогнозних моделей у медицині для покращення профілактики геморагічної лихоманки з нирковим синдромом (ГЛНС), яка є важливим викликом для громадського здоров'я в Китаї [154]. Вони запропонували модель ARIMA-GRNN і отримали такі результати: для ARIMA RMSE склало 220.6269/MAPE 21.02, для GRNN RMSE — 202.1684/MAPE 19.20, а найкращою виявилася гібридна модель ARIMA-GRNN із RMSE 196.4682/MAPE 17.83. Дослідники дійшли висновку, що їхній підхід може стати ефективним інструментом підтримки прийняття рішень у сфері профілактики та контролю ГЛНС. У схожій площині працювали й Li та колеги [155], ними було запропоновано метод для медичної сфери, спрямований на прогнозування захворюваності на туберкульоз. В їхньому дослідженні використовувалися дані про захворюваність у місті Ляньюньган за період із січня 2007 року по червень 2016 року. Автори розробили гібридний підхід, який інтегрує ARIMA-модель і штучну нейронну мережу GRNN. Результати дослідження Li та співавторів продемонстрували

вищу ефективність гібридної ARIMA-GRNN моделі (RMSE: 0,2805; MAPE: 8,8797) порівняно з окремою ARIMA-моделлю (RMSE: 0,2553; MAPE: 5,7222) при короткостроковому прогнозуванні захворюваності на туберкульоз у китайській популяції. Крім того, автори акцентували увагу на тому, що їхній гібридний підхід [155] особливо добре впорався із завданням моделювання піків і мінімумів захворюваності, що є критично важливим для забезпечення точності прогнозування.

2.5.11.2. Гібридні методи з використанням вейвлет-декомпозиції

Ченг та його колеги розробили метод прогнозування приземної концентрації озону, оскільки, на їхню думку, ця проблема становить серйозну загрозу людському здоров'ю та росту рослинності [156]. Для своїх досліджень вони використали дані про концентрацію приземного озону в Шеньчжені. У дослідженні було протестовано різні алгоритми декомпозиції, набір даних і ключові фактори. Вони визначили, що вейвлет-перетворення у їхньому випадку демонструє кращу ефективність [156] порівняно з такими методами, як емпірична модальна декомпозиція (EMD), ансамблева емпірична модальна декомпозиція (EEMD) та повна ансамблева емпірична модальна декомпозиція з адаптивним шумом (CEEMDAN). Запропонований ними гібридний метод отримав назву WD-LSTM-SVR. Спочатку вони здійснювали розкладання даних на кілька рівнів за допомогою вейвлет-розкладання (WD), після чого кожен шар аналізували і прогнозували за допомогою LSTM та SVR. Ця комбінована методика продемонструвала значно кращі результати (RMSE: 4,7383; MAPE: 7,9348) порівняно з окремими підходами. Зокрема, модель LSTM у їхньому дослідженні досягла RMSE 12,2361 і MAPE 23,2028 [156]. Інше дослідження провели Wu та його співавтори, які розробили гібридний підхід для прогнозування опадів і посух у північних провінціях Китаю. Вони використовували довгостроковий щомісячний набір даних з 1967 по 2017 рік для трьох метеорологічних станцій [157]. Методика базувалася на поєднанні ARIMA та LSTM, доповнених дискретним вейвлет-перетворенням. Їхній гібридний підхід перевершив точність окремих моделей ARIMA (RMSE:

0,13342; MAPE: 0,72) та LSTM (RMSE: 0,07; MAPE: 0,56) [157], досягнувши RMSE 0,06633 і MAPE 0,51. Чжан зі співавторами запропонували модель WAARMA-BP, яка поєднує авторегресійне вейвлет-перетворення, ARMA та BPNN для прогнозування глибини підземних вод, щоб передбачити глибини підземних вод з залученням перехресної перевірки методом залишення одного пропущеного елемента(LOOCV) [158]. Для навчання вони використовували дані з 1981 по 2021 рік, отримані з північно-західного регіону Китаю. Оцінювання моделі проводилось за RMSE. Результати продемонстрували значно вищу ефективність гібридного підходу (RMSE: 0,0136) порівняно з окремою моделлю ARMA (RMSE: 0,05) або BPNN (RMSE: 0,0797) [158]. Зі свого боку Eua-Arporn та його команда представили підхід EWT-ARIMAANN, який базувався на використанні емпіричного вейвлет-перетворення разом із ARIMA та ANN [159]. Емпіричне вейвлет-перетворення дозволяло розбивати початковий часовий ряд на підсерії, що відображали унікальні характеристики різних частотних складових. Для перевірки ефективності цього методу було використано чотири набори даних: сонячна активність (плями), AQI, бензин та CO₂. Запропонована модель EWT-ARIMAANN досягла значення RMSE 13,966 і перевершила результати окремих ARIMA (RMSE: 17,385) та ANN (RMSE: 18,561) [159]

2.5.11.3. Гібридні методи прогнозування

У рамках цього дослідження, проведеного за методологією PRISMA, було ґрунтовно проаналізовано різноманітні реалізації гібридних підходів до прогнозування часових рядів. У деяких випадках автори застосовували принципово різні методи для моделювання часового перебігу даних, які були отримані з різноманітних галузей наукових та прикладних досліджень. Такі сфери включали економіку, екологію та медицину. В економіці, наприклад, розглядалися моделі прогнозування темпів інфляції на основі аналізу індексів [160], прогнозування валютних курсів [161] та оцінювання валового внутрішнього продукту країни [153]. В екологічному контексті дослідники приділяли увагу моделюванню температури ґрунту [162], оцінюванню

концентрації стійких органічних забруднювачів (СОЗ) [163], прогнозуванню змін рівня моря та води [164, 165], глибини залягання підземних вод [158], а також концентрації приземного озону [156]. У медичній сфері основну увагу було спрямовано на прогнозування захворювань з акцентом на профілактику та контроль, що демонструє значущий приклад потенційного застосування гібридних методів [154, 155].

Дві узагальнені гібридні стратегії були презентовані Хадваном і співавторами [152, 159], а також Еуа-Арпорном з колегами. Хадван та інші запропонували підхід ARIMA-BPNN, який вони застосували до різноманітних наборів даних, зокрема для аналізу показників індексу споживчих цін і прогнозів у сфері онкології. Їхня модель показала позитивні результати для обох сценаріїв використання, причому найкращі показники були досягнуті у випадку даних про онкологічні захворювання [152]. Натомість Еуа-Арпон із колегами використали гібридну модель EWT-ARIMA-ANN, яка інтегрує емпіричне вейвлет-перетворення (EWT) з методологіями ARIMA та штучної нейронної мережі (ANN). Цей підхід був застосований до прогнозування чотирьох різних типів даних: сонячних плям, індексу якості повітря (AQI), обсягів споживання бензину та рівнів викидів CO_2 . Результати дослідження свідчать, що їхня гібридна модель перевершила за точністю кожен зі складових моделей для всіх категорій даних [159].

Результати нашого дослідження, отримані через методологію PRISMA, було згруповано в п'ять основних категорій:

- Перша категорія охоплює гібридні підходи, що поєднують ARIMA та LSTM [161-163, 166, 167];
- Друга категорія включає підходи, які використовують SARIMA разом із LSTM [144, 160, 164];
- Третя категорія об'єднує роботи, що асоціюють ARIMA або SARIMA із штучними нейронними мережами (ШНМ) [165-168];
- Четверта категорія характеризується підходами на базі нейронних мереж, що застосовуються рідше [151, 152, 154, 155];

– П’ята категорія представляє методи, що використовують декомпозицію через вейвлет-перетворення [154, 156, 158, 159].

Загалом можна відзначити, що основна маса проаналізованих досліджень зосереджується на гібридних методах, котрі інтегрують ARIMA або похідну від неї SARIMA з LSTM. Додатково до цього, особливе значення мають роботи, які вперше запропонували поділ лінійних і нелінійних компонентів із використанням вейвлет-перетворень. Для оцінювання результатів аналізу використовуються два ключових критерії — RMSE та MAPE. В ідеалі найточніші моделі повинні демонструвати нижчі значення цих метрик, що означає мінімальну різницю між прогнозованими та фактичними даними. Однак, уявити якийсь один підхід як універсально найкращий неможливо через залежність результатів від характеристик вхідних даних. На основі зібраної інформації можна зробити висновок, що гібридні моделі мають суттєві переваги щодо точності прогнозів з точки зору RMSE та MAPE серед усіх представлених методів. Суттєве покращення спостерігається як для здебільшого нелінійних даних, так і для лінійних.

2.5.11.4. Застосування гібридних підходів до прогнозування у візуальній аналітиці

Дослідження, проведене в рамках PRISMA, засвідчило значний потенціал впровадження гібридних підходів у прогнозуванні часових рядів у різних галузях. Гібридні методи вже знайшли застосування в багатьох практичних сферах, демонструючи перспективні результати. Навіть за умови використання одних і тих самих моделей для різних наборів даних, гібридні підходи перевершують традиційні статистичні моделі, які зазвичай застосовуються у візуальній аналітиці, та забезпечують суттєво кращі прогностичні результати. Інтеграція гібридних методів до конвеєрів трансформації візуальної аналітики відкриває нові можливості для підвищення якості процесів прийняття рішень.

Було адаптовано концепцію гібридного прогнозування до існуючої системи візуальної аналітики в рамках цього дослідження [171-173].

Рисунок 2.21 ілюструє приклад використання візуалізації прогнозу, що демонструє динаміку розвитку технологій із результатами прогнозування, отриманими за допомогою інтегрованого гібридного підходу [171, 173, 174]. Для опису майбутнього прогнозу було застосовано маркери меншої насиченості, значення яких визначаються параметрами середньоквадратичного відхилення алгоритму прогнозування.

Інтеграція гібридних підходів у сучасні системи візуальної аналітики та механізми ухвалення рішень представляє значний інноваційний потенціал. Зокрема, ці методи можуть вдосконалити стратегічне планування [173] шляхом удосконалення механізмів прогнозування майбутнього розвитку новітніх технологій, сприяючи покращенню корпоративного форсайту за допомогою візуальної аналітики. Ще одним важливим застосуванням є використання цих методів для моніторингу діяльності конкурентів або провідних експертів галузі. Вищий рівень точності прогнозів дозволяє ефективно оцінювати майбутній вплив конкретних осіб або подій, що слугує додатковим інструментом для підтримки процесів ухвалення рішень [175].




Рисунок 2.21 – Приклад використання інтегрованого гібридного підходу в системі візуальної аналітики. Майбутнє прогнозування представлено через малий рівень насиченості, який визначається величинами

середньоквадратичного відхилення прогнозного алгоритму. По осі x відображено часовий інтервал з 2008 до 2025 року із кроком в один рік, тоді як по осі y представлена кількість наукових публікацій у діапазоні від 0 до 5000 із кроком у 1000.

2.5.11.5 Аналіз підходів до формування ансамблів штучних нейронних мереж

Ансамблі штучних нейронних мереж (ШНМ) являють собою сукупність різних топологій, об'єднаних в єдину інтегровану систему. Вони можуть відрізнятися за архітектурою, алгоритмами навчання, критеріями оптимізації процесу навчання та типами нейронів [169, 176, 177], які використовуються. У деяких випадках під ансамблями розуміють об'єднану модель, кінцевий результат якої є функціональним поєднанням вихідних даних окремих складових [163].

Вхідні дані для таких систем можуть бути поділені на різні сегменти для паралельної обробки окремими нейронними мережами або подаватися одночасно на всі елементи ансамблю.

Процес створення ефективного ансамблю ШНМ передбачає вирішення двох ключових завдань: забезпечення високої якості навчання кожної окремої моделі та визначення оптимального підходу до їхнього інтегрування. Сучасні алгоритми формування ансамблів поділяють на два основні класи [177]. До першого належать методи, що змінюють розподіл навчальних прикладів залежно від точності, досягнутої попередніми моделями, посилюючи значення неправильно класифікованих прикладів. Ці методи відомі як підходи бустінгу. До другого класу входять методи, у яких навчання нових моделей відбувається незалежно від існуючих, що характерно для підходів бегінгу. Особливості та недоліки основних алгоритмів об'єднання компонентів ансамблів ШНМ, наведено на рис. 2.22 та 2.23 [163].

Усереднення за ансамблем	Бегінг	Бустинг	Стекінг
Лінійна комбінація вихідних сигналів ШНМ	Формування множини ШНМ на основі сукупності підмножин навчальної вибірки й наступного об'єднання результатів роботи ШНМ	Кожна нова ШНМ базується на результатах раніше побудованих	Застосування концепції мета навчання
<ul style="list-style-type: none"> Залежність результату від правильного визначення компетентності ШНМ. Збільшення складності алгоритму за рахунок застосування алгоритмів корекції «шумових викидів». 	<ul style="list-style-type: none"> Додаткові обчислювальні витрати, пов'язані з необхідністю формувати велику кількість підмножин навчальної вибірки. Підмножини прикладів відрізняються одна від одної, але не є незалежними, оскільки всі вони засновані на тій самій множині. Для роботи алгоритму необхідна велика кількість даних для настроювання й навчання. 	<ul style="list-style-type: none"> Наявність більшої кількості прикладів навчальної вибірки. Виродження ансамблю ШНМ у складну неефективну нейромережеву структуру, що вимагає великої кількості обчислювальних ресурсів. Останні ШНМ навчаються на «найскладніших» прикладах. 	<ul style="list-style-type: none"> Складність теоретичного аналізу через безліч послідовно формованих моделей. Можливе розростання рівнів метамоделі, що може призвести до швидкого виснаження обчислювальних ресурсів.

Рисунок 2.22 – Особливості та недоліки основних алгоритмів об'єднання компонентів ансамблів ШНМ (статистичні структури)

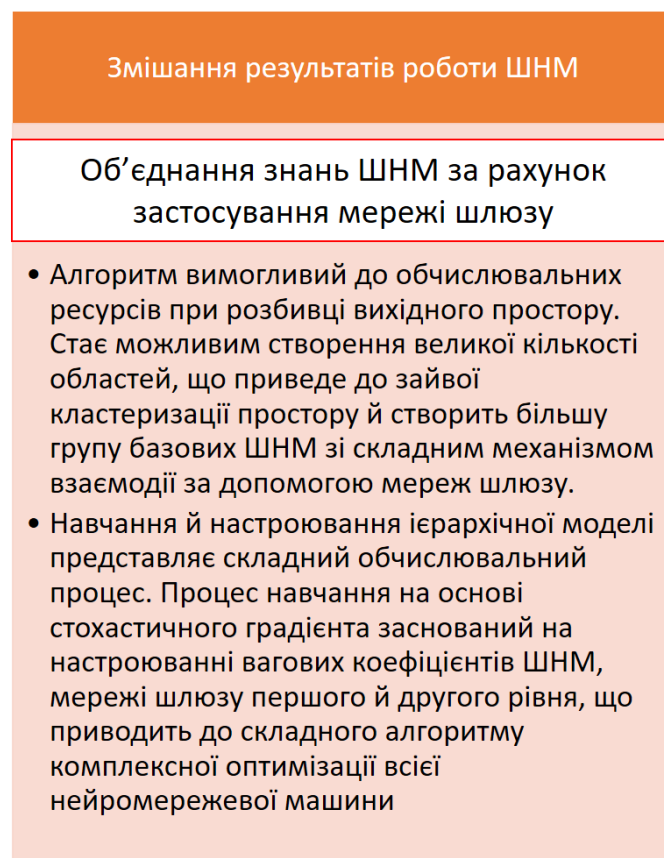


Рисунок 2.23 – Особливості та недоліки основних алгоритмів об'єднання компонентів ансамблів ШНМ (динамічні структури)

Сутність гібридних методів

Гібридні методи потребують чіткого відмежування від ансамблевих підходів, оскільки останні здебільшого є простими комбінаціями окремих прогнозів. Ансамблеві методи формалізуються математично як сума:

$$u = \sum_{m=1}^N w_m u(m) \quad (2.29)$$

де $u(m)$ - це окремі прогнози, що входять до спільного ансамблю, $m = 1, \dots, N$, а N позначає загальну кількість використаних моделей. Параметр w_m є ваговим коефіцієнтом, який визначає внесок кожного окремого прогнозу до фінального результату (Atiya). Основний принцип роботи ансамблевих моделей відображає концепцію управління ризиками, за якої поєднання прогнозів, одержаних різними підходами, може компенсувати недоліки будь-якої з моделей окремо (Atiya). Наприклад, дослідження Krogh і Vedelsby свідчить про те, що включення кількох регресійних моделей значно підвищує здатність систем до узагальнення. Аналогічний підхід утвердився в таких галузях, як метод випадкових лісів: ця техніка передбачає інтеграцію кількох дерев рішень для формування єдиного прогнозу (Breiman).

В умовах задач прогнозування гібридні методи відрізняються своєю складністю та інтегрованістю. Вони об'єднують статистичні алгоритми та методи машинного навчання на більш глибокому рівні взаємодії. Це значно перевищує межі звичайної агрегації незалежних прогнозів, яка притаманна ансамблевим підходам. Таким чином, гібридні моделі характеризуються принциповою відмінністю у своїй концептуальній організації.

Статистичні підходи та методи машинного навчання демонструють різні переваги у контексті прогнозування часових рядів. Однак недоліки цих методів вказують на обмеженість їх окремого застосування. Дані у таблиці 2.10 систематизують основні переваги й недоліки кожного з цих підходів, обґрунтовуючи необхідність їх синергетичного об'єднання у рамках гібридних моделей.

Таблиця 2.10

Переваги та недоліки статистичних методів і методів машинного навчання

	Переваги	Обмеження
Статистичні методи	Простота, зрозумілість Апріорні знання Ефективність при обмеженій доступності даних	Припущення про лінійність Відсутнє перехресне навчання
Методи машинного навчання	Без припущення про лінійність Універсальна апроксимація Перехресне навчання	Вимоги до даних Обчислювальні зусилля

Основна концепція гібридних методів полягає у поєднанні сильних сторін статистичних підходів і алгоритмів машинного навчання з метою мінімізації недоліків кожного з них. Зокрема, ефективність статистичних методів в умовах обмежених даних дозволяє компенсувати значну залежність машинного навчання від великих наборів даних. Крім того, залучення апріорної інформації сприяє суттєвій оптимізації прогнозування та зниженню обчислювальних витрат. Гібридні технології також надають можливість реалізовувати перехресне навчання, що зазвичай недоступне в суто статистичних методах. Водночас вони усувають обмеження, пов'язані з припущенням про лінійність моделей. У випадку прогнозування часових рядів варто враховувати, що ці ряди можуть бути лінійними, нелінійними, або ж комбінованими (Panigrahi та Behera). Хоча штучні нейронні мережі (ШНМ) довели свою ефективність у розв'язанні проблем ARIMA-моделей у контексті нелінійних взаємозв'язків, їх результати для суто лінійних часових рядів залишаються непослідовними. Таким чином, ні ARIMA, ні ШНМ не

забезпечують достатньої універсальності для адекватного моделювання реальних часових рядів (Khandelwal та ін.). У зв'язку з цим гібридні підходи мають на меті синтезувати найкращі характеристики обох методів для підвищення точності прогнозів.

Останнім часом гібридні методи привертають значну увагу дослідників, що сприяло появі великої кількості наукових праць. Наступний розділ пропонує огляд цих досліджень, аналіз найважливіших моделей і демонстрацію підходів до їхньої гібридизації.

Відповідні дослідження

Дослідження гібридних методів прогнозування часових рядів не є новаторською ідеєю, адже їх початок сягає майже двох десятиліть тому. Основоположний підхід до гібридизації було запропоновано у роботі Zhang, де автор поєднав методології ARIMA (авторегресійна інтегрована модель ковзного середнього) та MLP (багатошаровий перцептрон). Головна концепція полягала в тому, що MLP навчається на залишках між прогнозованими значеннями, отриманими за допомогою ARIMA, і фактичними даними, що дозволяє скоригувати ці залишки задля досягнення вищої точності моделі. Цей підхід обґрунтований, оскільки часові ряди часто мають складну структуру, яка включає як лінійні автокореляційні залежності, так і нелінійні компоненти. Математично це можна формалізувати так (Zhang):

$$y_t = L_t + N_t \quad (2.30)$$

де L_t представляє лінійну складову, а N_t відповідає за нелінійні компоненти.

Модель ARIMA орієнтована на моделювання лінійної складової часового ряду. Водночас залишки, що виникають після застосування ARIMA, відображають інформацію про нелінійні залежності в даних (Zhang). Залишки визначаються як різниця між фактичними значеннями y_t та прогнозами \hat{L}_t , отриманими за допомогою ARIMA:

$$e_t = y_t - \hat{L}_t \quad (2.31)$$

Таким чином, запропонований Zhang підхід дозволяє ефективно комбінувати сильні сторони лінійного моделювання (ARIMA) та нейронних мереж (MLP) для врахування нелінійних аспектів.

Наступним етапом метод найменших квадратів (МНК) використовує залишки, отримані на попередньому кроці, як вхідні дані для навчання функції, яка здатна ефективно прогнозувати ці залишки. Така функція оцінює очікуване значення залишків. У результаті формується гібридний прогноз \hat{y}_t шляхом об'єднання результатів обох моделей: лінійної \hat{L}_t та нелінійної \hat{N}_t , що записується у вигляді:

$$\hat{y}_t = \hat{L}_t + \hat{N}_t \quad (2.32)$$

Дослідження, проведене Zhang у 2003 році, продемонструвало обнадійливі результати використання гібридного підходу. Тестування цього методу на трьох реальних часових рядах виявило значно вищу точність прогнозів у порівнянні з окремим використанням лінійних або нелінійних моделей. Утім, недоліком залишалася відсутність загальної діагностичної статистики для адекватного подання складних нелінійних залежностей, що обмежувало ефективність моделі Zhang.

Виходячи з цієї концепції, згодом були запропоновані численні удосконалення та модифікації моделі. Наприклад, дослідження Khandelwal зі співавторами спрямовувалося на вирішення проблеми відсутності діагностичних інструментів для аналізу нелінійних зв'язків. Вони застосували дискретне вейвлет-перетворення (DWT) у гібридній моделі ARIMA-MLP. У рамках цього підходу DWT розділяє часовий ряд на лінійну та нелінійну компоненти. Лінійну частину моделює ARIMA, а результат у вигляді залишків додатково аналізується за допомогою багатошарового перцептрона (MLP). Остаточний прогноз обчислюється шляхом об'єднання результатів обох моделей. Автори підкреслюють, що така інтеграція значно перевершує як ізольовані моделі, так і початковий підхід Zhang за точністю прогнозування Khandelwal. Domingos та його колеги також розвинули ідею гібридних моделей, змістивши акцент на методи поєднання лінійних і нелінійних

компонентів. Їхній підхід передбачає створення механізму машинного навчання для інтеграції результатів обох моделей у єдиний прогноз. Основна ідея полягає у знаходженні оптимальної функції, яка описувала б взаємозв'язок між загальним прогнозом часового ряду та залишковою компонентою. Найкращі результати було отримано із застосуванням регресії опорних векторів (SVR), яка зарекомендувала себе як ефективний інструмент для моделювання складних нелінійних залежностей (Domingos та ін.).

Орієнтуючись на модернізацію окремих компонентів, Panigrahi і Behera запропонували модель, що поєднує експоненційне згладжування з MLP. Це дало змогу суттєво підвищити точність передбачень. Однак прорив у цій галузі стався завдяки розробці моделі Smyl. Поєднання експоненційного згладжування з мережами довгої короткострокової пам'яті (LSTM) викликало значний інтерес серед дослідників у сфері прогнозування часових рядів. Наступний розділ буде присвячений детальному розгляду цієї моделі, її архітектури та практичної ефективності.

Гібридний підхід

У сучасних наукових дослідженнях для розв'язання задач прогнозування активно застосовуються як лінійні, так і нелінійні гібридні моделі. У рамках цього дослідження було розроблено новаторську гібридну модель, що поєднує архітектурні елементи довготривалої короткострокової пам'яті (LSTM) та модуля згорнутих рекурентних нейронів (GRU). Для формування навчальних і тестових вибірок дані поділялися у співвідношенні 70% до 30%, після чого нормалізувалися в межах інтервалу від 0 до 1 методом масштабування min-max. Такий підхід забезпечує ефективну адаптацію вхідних даних до заданих параметрів моделювання.

Структуру запропонованої моделі формують три основні шари. Перший шар — це блок LSTM, що складається зі 128 прихованих вузлів. Другий шар представлений модулем GRU із 64 прихованими нейронами, тоді як третій, вихідний шар, є щільним і включає один єдиний нейрон. Вихід із блоку LSTM передається до шару GRU, забезпечуючи багаторівневу обробку даних для

отримання інтегрованого результату прогнозування. Таким чином, запропонована архітектура базується на послідовній взаємодії компонентів, які утворюють єдину узгоджену структуру передачі й аналізу інформації. Модель реалізує свій функціонал через кілька етапів обробки. На початковому етапі вхідні дані, що представляють часові ряди (наприклад, рівень безробіття), подаються до блоку LSTM. Кожен прихований елемент цього шару генерує зважене значення, яке є проміжною оцінкою для прогнозування. Ці результати передаються до наступного компонента — шару GRU, де виконуються додаткові розрахунки для уточнення прогнозу. Потім інформація надходить до щільного шару, де одиничний вихідний нейрон генерує кінцеве значення прогнозованого параметра. Для забезпечення високої точності моделі використовується функція вартості, яка оцінює різницю між отриманим прогнозом і фактичними даними. На етапі навчання модель мінімізує функцію вартості, послідовно коригуючи коефіцієнти вагових значень для зменшення помилок прогнозування. Після кожного оновлення ваги фіксуються для забезпечення стабільності й точності під час майбутніх передбачень. Схематична реалізація запропонованої архітектури наведена на рис. 2.24, який ілюструє ключові аспекти її структури та процес обробки інформації між окремими шарами.

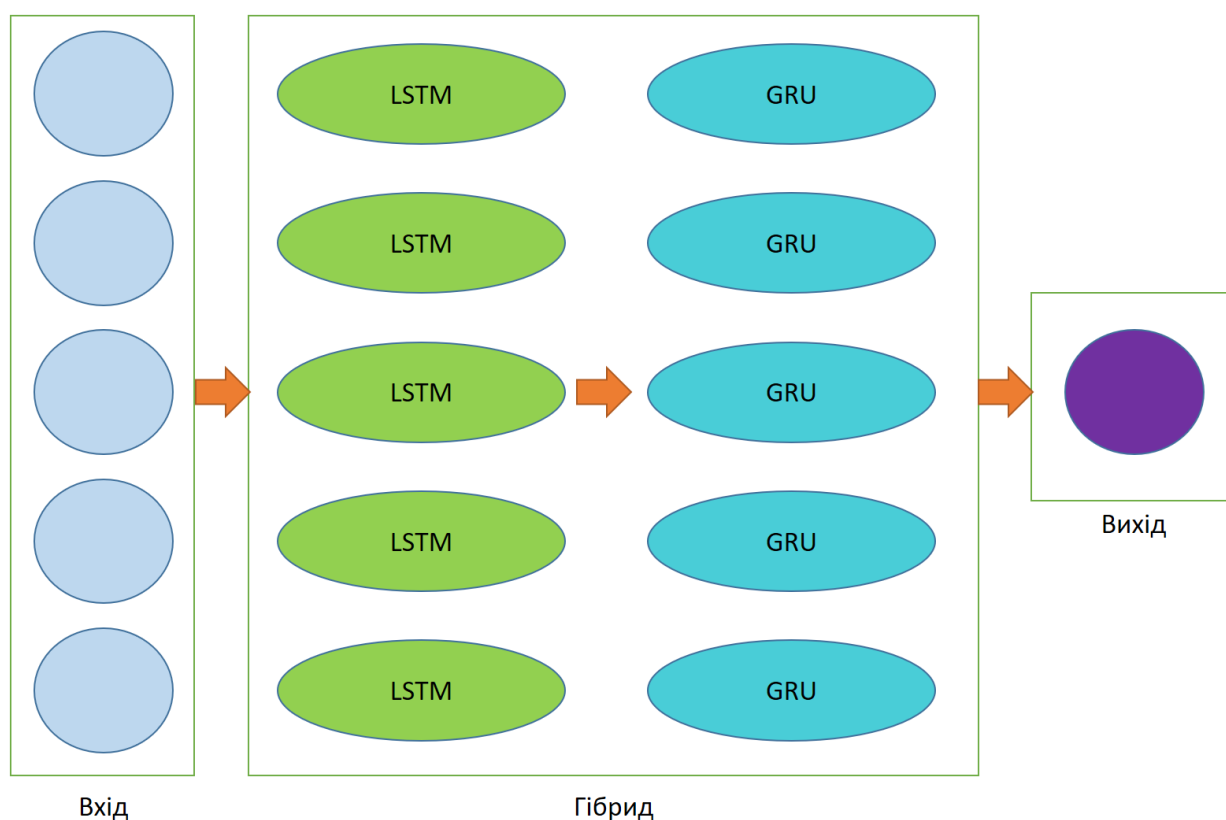


Рис. 2.24 – Гібридний метод

З метою підвищення точності прогнозування в роботі запропоновано створення гібридних нейронних мереж. В якості можливих варіантів розглянуто такі топології LSTM-GRU (рис. 2.25, табл. 2.11), 2 LSTM-2 GRU (рис. 2.26, табл. 2.12), 4 LSTM-4 GRU (рис. 2.27, табл. 2.13).




Рисунок 2.25 – LSTM-GRU

Таблиця 2.11

Метрики помилок LSTM-GRU

Метрики	Прогнозування 1 крок	Прогнозування 3 кроки	Прогнозування 5 кроків
MAE	0.14571757197380067	0.235571373462677	0.24793088555336
MAPE	77.41872833251954	126.78560083007812	125.47924682617187

Метрики	Прогнозування 1 крок	Прогнозування 3 кроки	Прогнозування 5 кроків
MSE	0.06484194427728653	0.18074594831466675	0.19647163271903992
RMSE	0.18596352219581605	0.29595776295661924	0.30650529384613034




Рисунок 2.26 – 2 LSTM-2 GRU

Таблиця 2.12

Метрики помилок 2 LSTM-2 GRU

Метрики	Прогнозування 1 крок	Прогнозування 3 кроки	Прогнозування 5 кроків
MAE	0.13342227697372436	0.16332850646972658	0.16637203335762024
MAPE	92.52266784667968	93.32590899658203	110.01583618164062
MSE	0.05750887006521225	0.08907050681114197	0.09585623681545258
RMSE	0.18080406546592712	0.21379239153862	0.21915608882904053




Рисунок 2.27 – 4 LSTM-4 GRU

Таблиця 2.13

Метрики помилок 4 LSTM-4 GRU

Метрики	Прогнозування 1 крок	Прогнозування 3 кроки	Прогнозування 5 кроків
MAE	0.12750604450702668	0.1837962293624878	0.14740030765533446
MAPE	87.81119842529297	120.94832366943359	92.17434387207031

Метрики	Прогнозування 1 крок	Прогнозування 3 кроки	Прогнозування 5 кроків
MSE	0.050095555186271665	0.11866544425487519	0.0723742127418518
RMSE	0.17371360659599305	0.2388857924938202	0.19645367860794066

Наведено графічне порівняння всіх використаних нейронних мереж за середньою абсолютною похибкою (рис. 2.28), середньою квадратичною похибкою (рис. 2.29), коренем середньої квадратичної похибки (рис. 2.30).




Рисунок 2.28 – Середня абсолютна похибка




Рисунок 2.29 – Середня квадратична похибка




Рисунок 2.30 – Корінь середньої квадратичної похибки

Порівняння за чотирма метриками по всіх НМ з якими проводилися розрахунки представлені в табл. 2.14 та табл. 2.15.

Таблиця 2.14

Порівняння нейронних мереж за метриками MAE та MAPE

	MAE 1	MAE 3	MAE 5	MAPE 1	MAPE 3	MAPE 5
MLP	0.23018944 8595047	0.29727451 026439666	0.33516886 23428345	54.8085800 17089845	63.7517443 8476562	66.5408767 7001954
BNN	0.23996027 410030366	0.34328516 840934753	0.36592585 742473605	54.9596611 0229492	78.5795489 5019532	100.908644 10400391
k-NN	0.22718803 531252632	0.24229064 5688932	0.26936145 57386084	0.82588025 0358887	0.79210526 88943752	0.72937912 75665588
SVM	0.32022169 38802813	0.28138468 610687056	0.27906218 29839274	0.74617673 1121398	0.84187580 19218755	0.89501369 92980421
Дерева рішень	0.34881012 823403623	0.26259677 985716096,	0.23359279 69128856	1.28742042 90256246	0.82036417 46800283	0.66964306 82293664
LSTM	0.25087185 80007553	0.35047129 809856414	0.41805645 227432253	73.9083419 7998046	108.461316 22314454	124.952711 48681641
BI- LSTM	0.15286598 14596176	0.25482955 026626586	0.24249140 977859496	76.0985815 4296874	127.764672 36328125	112.483100 28076172
GRU	0.12439206 779003144	0.19116326 61819458	0.22548236 0124588	57.7888052 3681641	88.9526606 4453125	104.565421 4477539
LSTM- GRU	0.14571757 197380067	0.23557137 3462677	0.24793088 555336	77.4187283 3251954	126.785600 83007812	125.479246 82617187
2LSTM- 2GRU	0.13342227 697372436	0.16332850 646972658	0.16637203 335762024	92.5226678 4667968	93.3259089 9658203	110.015836 18164062
4LSTM- 4GRU	0.12750604 450702668	0.18379622 93624878	0.14740030 765533446	87.8111984 2529297	120.948323 66943359	92.1743438 7207031

Таблиця 2.15

Порівняння нейронних мереж за метриками MSE та RMSE

	MSE 1	MSE 3	MSE 5	RMSE 1	RMSE 3	RMSE 5
MLP	0.16029949 337244034	0.21444786 608219146	0.25251813 381910326	0.27363682 389259336	0.33731068 193912506	0.37640465 19994736
BNN	0.16334840 506315232	0.26241853 35636139	0.28738179 206848147	0.27797248 065471647	0.38685065 031051635	0.41208949 089050295

	MSE 1	MSE 3	MSE 5	RMSE 1	RMSE 3	RMSE 5
k-NN	0.15317126 688758925	0.16909994 288103186	0.19673615 230595795	0.26245077 88401562	0.27584655 17695237	0.30219451 47028736
SVM	0.24311915 525289	0.20160997 414351647	0.20590586 375640604	0.36645111 87126417	0.31995517 97005248	0.31641692 837053026
Дерева рішень	0.27630925 951039	0.18176697 130613997	0.17243016 179684353	0.39588609 789775664	0.29527709 40213837	0.25575569 704200696
LSTM	0.17330400 496721268	0.27765710 175037384	0.36782878 0412674	0.29144712 38851547	0.40076422 214508056	0.48002179 86106873
BI- LSTM	0.07520848 30403328	0.20251152 861118316	0.18145759 46331024	0.19640794 932842254	0.31549927 043914794	0.29841472 26810455
GRU	0.05029731 035232544	0.11382382 559776306	0.16329558 253288268	0.16363367 974758147	0.23882248 44932556	0.28357626 55735016
LSTM- GRU	0.06484194 427728653	0.18074594 831466675	0.19647163 271903992	0.18596352 219581605	0.29595776 295661924	0.30650529 384613034
2LSTM- 2GRU	0.05750887 006521225	0.08907050 681114197	0.09585623 681545258	0.18080406 546592712	0.21379239 153862	0.21915608 882904053
4LSTM- 4GRU	0.05009555 5186271665	0.11866544 425487519	0.07237421 27418518	0.17371360 659599305	0.23888579 24938202	0.19645367 860794066

Проаналізувавши наведені дані з таблиць 2.14 і 2.15 та рисунків 2.28, 2.29, 2.30 можна зробити висновки, що рекурентні нейронні мережі GRU та BI-LSTM краще справляються з задачею прогнозування на відміну від інших використаних мереж незалежно від зміни кроків прогнозування. В свою чергу гібридні рекурентні нейронні мережі працюють більш точно за рекурентні нейронні мережі зі збільшенням кількості мереж у їх складі.

2.6 Висновки до розділу 2

Обґрунтовано метод інтелектуального прогнозування артеріального тиску який включає інтелектуальну попередню обробку результатів

безманжетного вимірювання АТ та інтелектуальне прогнозування АТ пацієнта що дає можливість уникнути можливості виникнення інсультів або інфарктів.

Запропоновано підхід до попередньої обробки даних безманжетного вимірювання АТ на основі використання алгоритмів усунення аномальних викидів та очищення даних, що дає можливість покращити результати прогнозування АТ у хворих.

Запропоновано новий підхід прогнозування значень АТ у хворих за рахунок використання гібридних нейронних мереж які включають нейронні мережі довгої короткострокової пам'яті та вентильних рекурентних блоків що дозволяє підвищити точність прогнозування.

РОЗДІЛ 3. ІНТЕЛЕКТУАЛЬНА КЛАСИФІКАЦІЯ СТУПЕНЯ АРТЕРІАЛЬНОЇ ГІПЕРТЕНЗІЇ

3.1. Ступені артеріальної гіпертензії

В першому розділі роботи виконано аналіз щодо поширення АГ у світі та в Україні. Незважаючи на несприятливу інформацію про поширення гіпертензії її можна лікувати і за рахунок цього знизити рівень загроз пов'язаних з нею. Це можна зробити за рахунок вчасної діагностики яка на жаль у великому обсязі виконується вручну кожним лікарем окремо. В останні роки багато було зроблено з точки зору розширення інформації, яку можна отримати для пацієнта завдяки великого розширення об'єму спостережень. З одного боку великий об'єм здобутої інформації розширяє можливості по діагностування артеріальної гіпертензії, а з іншого боку вимагає залучення до обробки цієї інформації великої кількості фахівців, що ускладнює процес діагностування та вимагає значних витрат часу. Тому для усунення цих недоліків активно використовується штучний інтелект. При цьому слід відмітити, що для ефективної боротьби з наслідками артеріальної гіпертензії необхідно крім діагностування цієї хвороби додатково визначити її ступінь і таким чином вибрати оптимальний підхід до лікування. На даний час не має єдиного підходу до визначення цих параметрів, а головне не існує методів ефективного оцінювання цих параметрів.

Згідно Фремінгемської моделі існує 5 груп ризику хворих з підвищеним АТ [178]:

- мінімальний — вірогідність ускладнень і смерті від ССЗ протягом 10 років $< 5\%$;
- низький — шанс ускладнень і смерті протягом 10 років $< 15\%$;
- помірний — аналогічна ймовірність найнебезпечніших наслідків становить 15-20%;
- високий — 20-30%;
- найбільший — перевищує 30%.

3.2. Діагностика ступеня артеріальної гіпертензії

Основними джерелами даних для визначення ознак, які характеризують ступінь АГ є наступні:

- скарги пацієнта (стійке підвищення артеріального тиску протягом доби вище норми, головний біль різного характеру та ступеню вираженості, запаморочення, шум у вухах, почервоніння шкіри обличчя, біль в області серця, задишка при збільшенні фізичного навантаження, порушення зору;
- результати вимірювання артеріального тиску
- медичний анамнез (вік, стать, куріння, підвищений рівень холестерину
- цукровий діабет, захворювання, якими пацієнт раніше страждав або страждає в даний час, спадковий анамнез, тобто чи страждали на гіпертонію батьки, дідусі-бабусі хворого та інші близькі родичі);
- огляд лікаря
- електрокардіограма;
- біохімічний аналіз крові (рівень холестерину та ліпопротеїнів високої, низької та дуже низької щільності, рівень цукру);
- загальний аналіз крові ;
- додатковий аналіз крові на калій, магній, натрій, адреналін, норадреналін, альдостерон;
- аналіз крові на рівень гормонів щитоподібної залози;
- аналіз на рівень електролітів;
- загальний аналіз сечі (виявлення наявності білка або червоних кров'яних клітин);
- УЗД серця;
- УЗД черевної порожнини з нирками;
- УЗД судин.

Діагностика гіпертензії II ступеню

Гіпертензія II ступеню - це форма високого артеріального тиску, коли АТ знаходиться в проміжку $160 \leq \text{САТ} < 180$ мм.рт.ст. та $109 \leq \text{ДАТ} < 109$ мм.рт.ст.

Діагностика гіпертензії II ступеню починається з огляду лікарем, збору анамнезу та вимірюванням АТ. АТ вимірюється на обох руках пацієнта, в разі великої різниці між показниками – використовуються показники більшого тиску.

Якщо показники артеріального тиску підвищені, то лікар може порекомендувати додаткові обстеження та аналізи, як:

- аналіз крові;
- електрокардіограму (ЕКГ) (аномальні показники на ЕКГ наведено в табл. 3.1).

Таблиця 3.1

**Аномальні показники які можна виявити на ЕКГ та ЕхоКГ для
діагностики АТ 2 ступеню**

Гіпертрофія лівого шлуночка	
індекс Соколова — Лайона	> 35 мм
R в aVL	≥ 11 мм
вольтажний індекс Корнелла	> 28 мм (чоловіки) > 20 мм (жінки)
ІМЛШ	> 50 г/м ² (чоловіки) > 47 г/м ² (жінки)

– Ультразвукове дослідження серця (ехокардіографія): для оцінки структури і функції серця. (ЕхоКГ дозволяє в кілька разів точніше діагностувати ГЛШ; 8% виявлення ГЛШ на ЕхоКГ проти 2,1% виявлення ГЛШ на ЕКГ - Фремінгемське дослідження)

- Рентген грудної клітки: для оцінки розмірів серця і легень.
- Холтерівське моніторування: для постійної реєстрації електричної активності серця протягом 24 годин.
- Моніторування артеріального тиску: для запису показників тиску протягом доби.

Також друга стадія артеріальної гіпертензії характеризується наявністю третьої стадія ХХН (рШКФ 30–59 мл/хв/1,73 м²); кісточно-плечовим індексом < 0,9; важкою ретинопатією (крововиливи або ексудати, папілоедема).

Лабораторні аналізи гіпертензії II ступеню

Під час діагностики гіпертензії II ступеню проводять такі лабораторні аналізи [179]:

- Загальний аналіз крові - дає змогу виявити наявність анемії або інших порушень у складі крові, що може вплинути на роботу серцево-судинної системи.
- Біохімічний аналіз крові - дає змогу оцінити рівень холестерину, глюкози, креатиніну та інших показників, які можуть бути пов'язані з гіпертонією.
- Загальний аналіз сечі - дає змогу оцінити роботу нирок і виявити наявність білка або червоних кров'яних клітин у сечі, що може вказувати на порушення в роботі нирок.
- Аналіз на рівень гормонів щитоподібної залози - дає змогу виявити порушення в роботі щитоподібної залози, які можуть бути пов'язані з гіпертонією.
- Аналіз на рівень метаболітів норадреналіну та адреналіну - дає змогу оцінити активність симпатичної нервової системи, яка може бути пов'язана з гіпертонією.

У таблиці 3.2 продемонстровано аномальні значення по кожному з лабораторних аналізів, яка дозволяють виявити артеріальну гіпертензію другого ступеня.

Таблиця 3.2

Аномальні значення лабораторних аналізів для виявлення АТ 2 ступеня

Аналіз	Аномальні значення
еритроцити	> 5,2 Т/л

Аналіз	Аномальні значення
лейкоцити	> 10,2 Г/л
гемоглобін	> 156 г/л
тромбоцити	> 389 Г/л
рівень білка	>82 г/л
рівень креатиніну	> 77 мкмоль/л
рівень холестерину (загального)	>5,2 ммоль/л
рівень цукру (глюкоза)	> 6 ммоль/л
калій	> 5,5 ммоль/л
магній	> 1,07 ммоль/л
натрій	> 146 ммоль/л
адреналін	> 125 нг/л
норадреналін	> 600 нг/л
альдостерон	> 30 нг/дл

Діагностика гіпертензії III ступеню

Артеріальна гіпертензія третьої ступеню характеризується попередніми ознаками першої та другої стадій, а також:

- наявністю в анамнезі цереброваскулярних захворювань (внутрішньомозкового крововилива, ішемічного інсульту, транзиторної ішемічної атаки);
- наявністю в анамнезі ішемічної хвороби серця (інфаркта міокарда, реваскуляризації міокарда, стенокардії);
- виявлення стенозу під час візуалізаційних досліджень;
- наявності тяжкої альбумінурії (> 300 мг/добу);
- наявності четвертої або п'ятої стадії ХХН (рШКФ < 30 мл/хв/1,73 м²).

3.3. Огляд методів інтелектуальної діагностики ступеня АГ

Опубліковано багато досліджень, в яких ШІ використовувався для діагностики або прогнозування виникнення гіпертонії в загальній популяції.

Нещодавні дослідження показали, що алгоритми DL або ML можна використовувати для діагностики клінічно важливих станів, таких як маскована неконтрольована гіпертензія або вторинна гіпертензія, використовуючи не тільки великі дані з електронних медичних карток (ЕМК), але й легко ідентифіковані клінічні ознаки, такі як офісний АТ, пульсовий тиск, використання бета-блокаторів та рівень холестерину ліпопротеїдів високої щільності (ХС ЛПВЩ). Крім того, було кілька спроб діагностувати АГ за допомогою амплітуди та вольтажу хвиль ЕКГ. В роботі [180] пропонується засіб обчислювального інтелекту (СІТ), що використовує сигнали електрокардіограм (ЕКГ) для НРТ і можливого виявлення МНРТ. Розклад емпіричного режиму (EMD) використовується для розкладання попередньо оброблених сигналів до п'яти рівнів. Після цього нелінійні характеристики витягуються з п'яти функцій внутрішнього режиму (IMF). Згодом для вибору набору високодискримінаційних ознак використовується t-критерій Стюдента. Потім цей набір функцій вводиться в різні класифікатори, у яких найкращу точність 97,70% забезпечує класифікатор k-найближчого сусіда (k-NN). Розроблений інструмент оцінюється методом 10-кратної перехресної перевірки. Наші висновки свідчать про те, що розроблена система є корисною для діагностичного обчислювального інтелектуального інструменту в лікарняних умовах і що вона дозволяє автоматично класифікувати НРТ проти нормальних сигналів ЕКГ. У роботі [] запропоновано підхід, який забезпечує більш надійну та економічно ефективну діагностику та аналіз морфології ЕКГ, що потенційно може бути використано для ідентифікації НРҮ (гіпертензії) у ситуаціях, коли артеріальний тиск на місці спостерігається як нормальний, наприклад МНР (маскована гіпертензія). В першій методології, яка використовує декомпозицію емпіричного режиму, спочатку завантажені необроблені сигнали ЕКГ будуть оброблені для сегментації та усунення шумів. Знешумлення – це видалення перешкоди різних шумів, таких як перешкоди лінії електропередач і дрейф базової лінії. Потім оброблені сигнали ЕКГ будуть розкладені на п'ять рівнів за допомогою емпіричного режиму

декомпозиції. Нелінійні характеристики будуть виділені з розкладених сигналів ЕКГ. Виділені ознаки пройдуть Т-тест для відбору найбільш характерних ознак ($P \leq 0,05$). Вибрані функції будуть використовуватися для класифікації сигналів ЕКГ на здоровий або НРҮ клас. В другій методології, яка використовується з технікою CNN, по-перше, завантажені необроблені сигнали ЕКГ будуть оброблені для сегментації та усунення шумів. Потім оброблені сигнали ЕКГ будуть передані в модель CNN, модель CNN вивчатиме та ідентифікуватиме унікальні сигнатури ЕКГ і класифікуватиме сигнали здорової ЕКГ і сигнали НРҮ.

В роботі [181] представлено штучну нейронну мережу (ANN) для прогнозування пацієнтів з гіпертонічною хворобою, використовуючи набір даних канадської дозорної мережі первинної медичної допомоги (CPCSSN). Незалежними характеристиками були вік, стать, ІМТ, систолічний і діастолічний артеріальний тиск, ліпопротеїни високої і низької щільності, тригліцериди, холестерин, мікроальбумін і співвідношення альбумін-креатинін в сечі. Для вимірювання точності моделі використовувалися матриця помилок і крива робочих характеристик приймача (ROC). У цьому документі використано великий набір даних для навчання моделі порівняно з іншими дослідженнями.

В роботі [182] представлено штучну нейронну мережу для класифікації серцево-судинних захворювань, включаючи гіпертонію; ця стаття використовувала китайське населення. Статистичний аналіз показав, що 14 факторів ризику показали статистичну важливість для серцево-судинних захворювань. крива ROC використовується для вимірювання продуктивності моделі.

В роботі [183] реалізовано багатошаровий персептрон для класифікації пацієнтів з гіпертонічною хворобою. Використаними незалежними характеристиками були вік, стать, сімейна історія гіпертонії, звички куріння, ліпопротеїни, тригліцериди, сечова кислота, загальний холестерин та індекс

маси тіла (ІМТ). Крива ROC використовується для вимірювання точності моделі.

В роботі [184] побудовано модель нейронної мережі для моделювання зв'язку генендофенотип-захворювання для тайванських чоловіків з гіпертонією. Шістнадцять генів, вік, ІМТ, рівень цукру в крові натще, ліки від гіпертонії, відсутність раку, нирок, печінки чи легенів в анамнезі. Точність класифікації використовується для вимірювання ефективності моделі.

Аналіз результатів приведених робіт дозволяє зробити висновок, що кількість використаних ознак для визначення ступенів гіпертензії у хворих є недостатнім, а топології застосованих нейронних мереж є застарілими.

Розглянемо використання сучасних інтелектуальних технологій, зокрема гібридних, для розв'язання задачі для визначення ступенів гіпертензії у хворих.

В якості гібридних інтелектуальних технологій пропонується використати ансамблеві.

3.4. Інтелектуальні ансамблеві технології

Структуру ансамблевих технологій наведено на рис.3.1.



Рис.3.1 – Структура ансамблевих технологій

Поєднання кількох прогнозів з відмінних моделей відоме, як ансамблеве навчання. Інтегровані певним чином моделі роблять навчання краще, ніж будь який окремо взятий процес. Таке злиття є витонченим підходом до збільшення продуктивності та кращого результату.

Літературні джерела зосереджені на огляді навчання ансамблевих моделей у задачах класифікації [185-188], задачах регресії [189,190] і кластеризації [191].

Продуктивність моделей збільшували за допомогою деяких класичних, загальних методів, та різних стратегій злиття. Ансамблеві моделі є обчислювальними; великими за обсягом; в структурі знаходиться декілька алгоритмів. Тому під час навчання ці процеси потребують підвищеної уваги. Зберігати час для навчання, викликати різноманітність серед базових моделей, об'єднувати передбачення додаткових алгоритмів, зберігати низьку складність моделей – це ті задачі, які повинні вирішувати ансамблеві моделі.

Ансамблеві методи стали успішними завдяки збільшенню різноманіття серед базових класифікаторів [192]. Генеруючи множинні набори з вихідних даних, вони навчають різні предиктори. Для цього використовують такі методи, як: агрегація бутстрепа (беггінг) [193], адаптивний бустинг (AdaBoost) [194], випадковий підпростір [195] і випадковий ліс [196]. При спробі збільшити різноманітність вихідних даних замість множинних наборів створювались множинні виходи. Серед таких підходів є «розмивання вихідних даних» [197]. Цей процес викликає випадковий шум, який вносить різноманіття у вихідний простір.

Як вже зазначалося в підрозділі 2.5.11, стратегії ансамблю класифікуються наступним чином.

3.4.1. Беггінг

Беггінг (бутстрап-агрегування) [198] вважається стандартним методом генерації ансамблевих алгоритмів. Завдяки йому підвищується продуктивність ансамблевого класифікатора. Ідеєю беггінгу є генерація декількох незалежних спостережень, з таким же розподілом, як у вихідних

даних. Завдяки спостереженням генерується ансамблевий предиктор, який стає кращою версією в порівнянні з одиночним, що згенерований на вихідних даних. У вихідних моделях беггінг генерує вибірки та передає у базові моделі, а також стратегічно об'єднує передбачення кількох предикторів. Генеруються вибірки з заміною або без неї. Для завдань класифікації використовують більшість голосів, тому об'єднання вихідних даних базових предикторів може відрізнитися. В той же час стратегія усереднення застосовується в завданнях регресії для створення вихідних даних ансамблю.

Схема методу беггінгу відтворена на рисунку 3.2, де D - набори даних, C - алгоритми, а F_{ens} - кінцевий результат.




Рисунок 3.2 – Беггінг

Витратний за кількістю обчислень беггінг призвів до введення суббеггінгу та напівсуббеггінгу [199]. Останній, за обчисленнями став ефективнішим та залишився точним, як беггінг.

Проблему незбалансованих даних намагалися вирішити, застосовуючи беггінг. В задачах бінарних класів, грубо збалансований беггінг [200], намагається зрівняти ймовірність вибірки кожного класу. Замість зберігання однакового розміру вибірки кожного класу, від'ємні зразки класів обираються за допомогою негативного біноміального розподілу. Генерація зразків беггінгу для задач дисбалансу класів відбувається завдяки збалансованому беггінгу, який включив інформацію про сусідство [201]. В останніх методах класифікації застосування звичайної диверсифікації є більш ефективним. Такого висновку дійшли Блащинський і Стефановський [201]. В архітектурах глибокого навчання, збалансований та грубо збалансований беггінг по сусідству досліджені не були. Ці підходи глибоких ансамблевих моделей слід використовувати для вирішення проблем дисбалансу класів.

За наявності обладнання для запуску уподібнених моделей, можна розпаралелювати беггінг, що ефективно зменшить час навчання і нівелює збільшення обчислювальної складності ансамблювання. Оптимізація декількох глибоких моделей в різних навчальних мішках не є здійсненним, так як моделі мають великий час навчання.

3.4.2. Бустинг

Для перетворення слабкої моделі навчання на модель з кращим узагальненням використовується бустинг. На рисунку 3.3 відтворено техніку бустингу. До кращого прогнозування, порівняно з одним слабким учнем, призводять голосування більшості в разі проблем класифікації або лінійна комбінація слабких учнів у задачах регресії. AdaBoost і градієнтний бустинг [202] – методи бустингу, які застосовують в різних галузях. AdaBoost використовує мінімізацію опуклої сурогатної функції, обмеженої зверху втратою неправильної класифікації, за допомогою аугментації на кожній ітерації поточної моделі з відповідним зваженим предиктором.

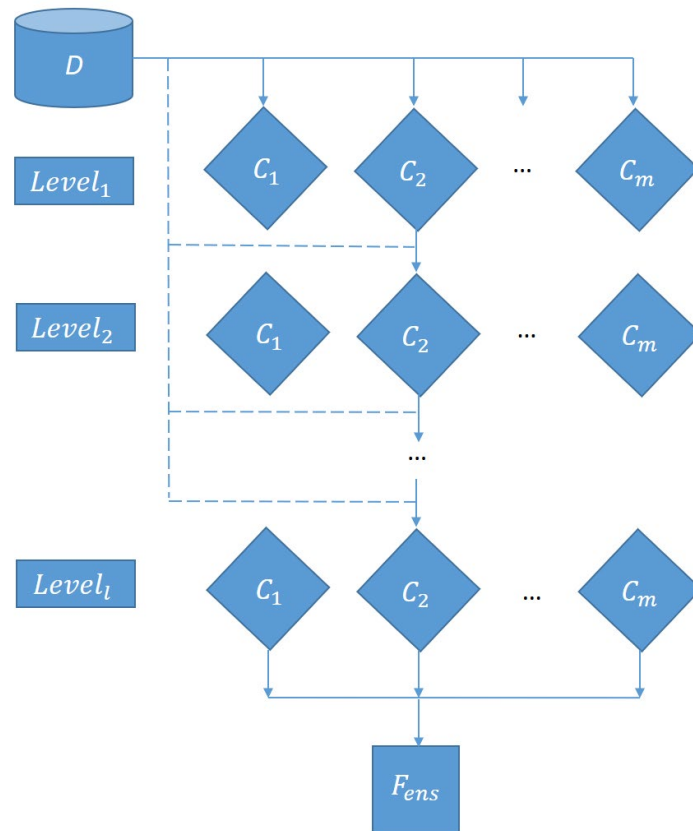


Рисунок 3.3 – Бустинг

AdaBoost використовує неправильно класифікований зразок на кожному етапі навчання. Таким чином AdaBoost навчається ефективному ансамблевому класифікатору та мінімізує експоненціальну функцію втрат. В цей час градієнтний бустинг узагальнює цю структуру до довільної диференціальної функції втрат.

Ансамблева модель, яка використовує глибокі дерева рішень називається глибоким бустингом [203]. Для поліпшення продуктивності узагальнення, цю модель можна використовувати в поєднанні з будь-яким іншим класифікатором сімейства. В залежності від складності класифікатора, до якого він належить, приймаються рішення про те, який класифікатор додати і які ваги слід вибрати. Так відбувається на кожному етапі глибокого бустингу. За допомогою принципу мінімізації структурного ризику на кожному етапі навчання, робиться інтерпретація класифікатора глибокого бустингу. Для багатокласових проблем глибокий бустинг [204] розширив алгоритм [203] до теоретичних, алгоритмічних та емпіричних результатів.

В дослідженнях, які проводились над ансамблем, оцінили різні алгоритми на основі концепції беггінг – бустинг та перевірили доступність програмних інструментів [205]. Були виявленні практичні проблеми та можливості їх вирішення в ансамблевому моделюванні.

3.4.3. Стекінг

Для об'єднання в ансамбль використовується метод вибору «найкращої» базової моделі. Також є шляхом об'єднання виходів цих моделей. На рисунку 3.4 відтворено метод стекування.




Рисунок 3.4 – Стекінг

Метод, в якому модель метанавчання застосовується для інтеграції вихідних даних базових моделей називається стекуванням. Його ще називають «змішуванням моделей» [206]. В порівнянні з лінійною моделлю, яка є остаточною частиною рішення, цей метод розділяє набори даних довільним

чином та ділить їх на J рівних частин. Один набір використовують для тестування в рамках j -кратної перехресної перевірки, а інший для навчання. Ці парні підмножини навчання та тестування дають прогнози різних моделей, що використовуються в якості метаданих для побудови метамоделі. Остання робить фінальний прогноз, який ще називають «переможець отримує все».

Stacking - метод зниження зміщення [207]. Було запропоновано глибоку опуклу мережу (DCN) [206,208], яка є архітектурою глибокого навчання та створена зі змінної кількості модулів, що склалися разом для формування глибокої архітектури. У DCN кожен навчальний модуль є опуклим і представляє стек з кількох ланок, які утворюються з лінійних вхідних одиниць, нелінійних одиниць прихованого шару та другого лінійного шару, з числом одиниць, що дорівнює числу цільових класів класифікації. Пошарове з'єднання модулів дає змогу подати вихід нижньої ланки, як вхід для даних сусіднього вищого модуля на додаток до вихідних даних.

DSN немає тимчасового представлення даних, тому вони менш ефективні для завдань, де існують тимчасові залежності у вхідних даних. Рекурентні глибокі стекові мережі (R-DSN) [209] об'єднали переваги DSN і рекурентних нейронних мереж (RNN) для вбудовування часової інформації в DSN. R-DSN використовують мережу відлуння-станів (ESN) для ініціалізації ваг, а потім їх тонкого налаштування за допомогою пакетного градієнтного спуску, на відміну від RNN, які використовують зворотне поширення в часі для навчання мережі.

В дисертаційному дослідженні використовувався ансамбль з паралельною структурою та шаром об'єднання, даний вибір зроблено після попереднього аналізу.

Для того щоб ансамбль мав більшу точність при класифікації порівняно з окремими НМ, необхідно щоб він складався з точних і різноманітних НМ. Необхідно знайти оптимальне компромісне рішення між точністю та різноманітністю, у зв'язку з тим, що при збільшенні точності членів ансамблю зменшується різноманітність [210].

Зазвичай якщо маніпулювати даними вибірки (навчальної), то можна досягнути бажаних значень точності та різноманітності, цей принцип діє для переважної частини ансамблевих методів. Однак схильність до побудови занадто великих ансамблів є суттєвим недоліком для цих підходів, це обумовлено збереженням навчених класифікаторів, тобто використанням великої кількості пам'яті. Щоб усунути даний недолік використовують спрощення, воно має відібрати найоптимальніше співвідношення по витратах пам'яті, різноманіттю та точності серед окремих класифікаторів, які знаходяться у складі побудованого ансамблю.

Виходячи з аналізу, наведеному в підрозділі 3.4, можна зробити висновок, що бегінг має переваги перед іншими інтелектуальними ансамблевими технологіями, а саме:

- нечутливий або малочутливий до шумів;
- зменшує помилки та збільшує стабільність за рахунок зниження дисперсії без підвищення зміщення;
- навчання елементів ансамблю відбувається паралельно;
- на відміну від інших класифікаторів зі складу ансамблю, бегінг підвищує точність роботи ансамблю (цей фактор може нівелювати додаткові обчислювальні витрати, які необхідні для його реалізації).

3.5 Постановка завдання інтелектуальної діагностики ступеня АГ

Розглянемо множину даних $D = \{d_1, \dots, d_N\}$, яка складається з N точок, де кожна точка $d_i = \{(x_i, y_i) \mid i \in [1, N]\}$ визначає набір вхідних ознак x_i і мітку y_i , що характеризує її. Також наявна множина класифікаторів $C = \{c_1, \dots, c_M\}$, де кожен класифікатор $c_i(x_j)$ виконує прогноз для точки x_j . Додатково розглядається множина векторів $V = \{v^{(1)}, \dots, v^{(N)}\}$, де кожен вектор $v^{(i)} = [v_1^{(i)}, \dots, v_L^{(i)}]$ відображає кількість передбачень для кожної з L можливих міток точки і при застосуванні мажоритарного голосування [210].

Завдання полягає у виборі підмножини класифікаторів із $C = \{c_1, \dots, c_M\}$ на основі їхньої точності та різноманітності для створення ефективного ансамблю. Для цього необхідно мати тестовий набір даних і вважати, що мережі були навчені на бутстреп-вибірках.

Різнорманітність може бути досягнуто за рахунок навчання елементів ансамблю на різних наборах даних. Дані можна отримати якщо використовувати бутстреп метод. Нейронні мережі мають бути елементами ансамблю, це забезпечить критерій точності.

Метод бутстрепа базується на багаторазовому вибіркового відборі з початкового емпіричного розподілу даних за допомогою Монте-Карло. З вихідної вибірки, що складається з n елементів (x_1, x_2, \dots, x_n) , випадковий елемент x_k обирається на кожній з n ітерацій за допомогою рівномірного генератора випадкових чисел і повертається назад у вибірку, що дозволяє його повторне використання. Першим етапом створення ансамблю є побудова базових класифікаторів. Їхня незалежність забезпечується тренуванням на різних підвибірках. Алгоритм побудови ансамблю включає такі основні кроки:

- 1) Створення бутстреп-вибірок. На основі початкової вибірки генерується кілька підвбірок однакового розміру шляхом випадкового відбору з поверненням.
- 2) Навчання базових класифікаторів. Для кожної бутстреп-вбірки тренується окремий нейронний класифікатор.
- 3) Відбір моделей. Оцінюються точність та різноманітність отриманих класифікаторів, після чого формується підмножина моделей для ансамблю.
- 4) Агрегація прогнозів. Сформований ансамбль інтегрує прогнози через мажоритарне голосування або іншу методику комбінування.

3.6 Побудова архітектури ансамблів нейронних мереж

Для того щоб побудувати ансамбль необхідно попередньо створити основні класифікатори. Вимога до основних класифікаторів – це їх незалежність. Класифікатори мають навчатися на незалежних наборах даних.

Алгоритм побудови архітектури ансамблів НМ має вигляд [210]:

- 1) Надано набір навчальних прикладів $(x_1, y_1), \dots, (x_m, y_m)$ з мітками $y \in \{1, \dots, k\}$;
- 2) Отримати t бутстреп-вибірок D_t ;
- 3) Незалежно (паралельно) навчити t класифікаторів h_t , кожен на своїй вибірці D_t .
- 4) Визначення рейтингу кожного класифікатора за критеріями точності та різноманіття;
- 5) Визначення складу ансамблю на основі рейтингу кожного класифікатора;
- 6) Розрахунок вагових коефіцієнтів кожного класифікатора в шарі об'єднання.

Тепер звернемо увагу на поняття різноманітності між класифікаторами.

Розглянемо два класифікатори c_i та c_j . Метрика $N^{(01)}$ показує кількість точок, які класифікатор c_i передбачив невірно, але класифікатор c_j — правильно. Водночас $N^{(10)}$ відображає зворотний випадок: кількість точок правильно передбачених класифікатором c_i , але помилково спрогнозованих класифікатором c_j . Багатогранність між класифікаторами c_i та c_j позначається як $Div_{i,j}$. Її обчислюють як відношення суми кількості точок, правильно класифікованих лише одним із двох класифікаторів, до загальної кількості точок. Ця залежність виражається рівнянням

$$Div_{i,j} = \frac{N^{(01)} + N^{(10)}}{N} \quad (3.1)$$

Частка багатогранності класифікатора c_i в ансамбль, або $ConDiv_i$, визначається як сума відмінностей між класифікатором c_i і кожним іншим класифікатором у ансамблі (окрім самого c_i , оскільки його власна різноманітність дорівнює нулю відповідно до рівняння 3.1). Це обраховується за формулою

$$ConDiv_i = \sum_{j=1}^M Div_{i,j} \quad (3.2)$$

Для задачі двокласової класифікації частка багатогранності класифікатора c_i можна представити у вигляді формули

$$ConDiv_i = \frac{1}{N} \sum_{k=1}^N (M - v_{c_i(x_k)}^{(i)}), \quad (3.3)$$

де:

- N — загальна кількість точок у вибірці,
- M — загальна кількість класифікаторів у ансамблі,
- $v_{c_i(x_k)}^{(i)}$ кількість тих класифікаторів в ансамблі, які мають ідентичні результати прогнозу для конкретної точки даних з класифікатором c_i .

Таким чином, оцінювання внеску окремого класифікатора в різноманітність ансамблю стає важливим етапом у процесі оптимізації продуктивності моделі.

У цьому контексті $M - v_{c_i(x_k)}^{(i)}$ кількість класифікаторів, які демонструють розбіжності з класифікатором c_i у процесі прогнозування результату, виступає ключовим параметром аналізу. У загальному випадку прогнозування, виконване членом ансамблю на одній вибірці даних, можна концептуально поділити на чотири категорії:

- 1) класифікатор забезпечує коректний прогноз і належить до меншості;
- 2) класифікатор забезпечує коректний прогноз і належить до більшості;
- 3) класифікатор формує некоректний прогноз і належить до меншості;
- 4) класифікатор формує некоректний прогноз і належить до більшості.

У межах дослідження було сформульовано два основоположні принципи для розробки евристичної метрики, спрямованої на оцінювання індивідуального внеску членів ансамблю:

- 1) прогнози, що є правильними, розглядаються як позитивний внесок, тоді як неправильні прогнози мають негативний вплив;
- 2) правильні прогнози, отримані від класифікаторів меншості, отримують вищу оцінку порівняно з правильними прогнозами від класифікаторів більшості. У той же час неправильні прогнози від

класифікаторів меншості викликають менший негативний вплив у порівнянні з аналогічними прогнозами від класифікаторів більшості.

Особиста частка класифікатора c_i визначається за допомогою наступної математичної формули

$$IC_i = \sum_{j=1}^N IC_i^{(j)}$$

у якій величина внеску $IC_i^{(j)}$ залежить від категорії, до якої належить прогноз у j -тій точці d_j .

Якщо $c_i(x_j) = y_j$ (тобто класифікатор c_i формує правильний прогноз у точці d_j і при цьому прогноз потрапляє до групи меншості (перша категорія), то внесок класифікатора визначається за допомогою формули

$$IC_i^{(j)} = 2v_{max}^{(j)} - v_{c_i(x_j)}^{(j)} \quad (3.4)$$

У цій формулі $v_{max}^{(j)}$ позначає кількість голосів, отриманих від групи більшості в точці d_j , тоді як відповідає числу прогнозів $c_i(x_j)$, що було попередньо обчислено.

У випадках, коли $c_i(x_j)$ відповідає y_j та належить більшості (зокрема, до другої підмножини $v_{c_i(x_j)}^{(j)} = v_{max}^{(j)}$), його значення розраховується згідно з формулою, наведеною у рівнянні

$$IC_i^{(j)} = v_{sec}^{(j)} \quad (3.5).$$

Тут розглядається кількість голосів $v_{sec}^{(j)}$, яка посідає друге місце за частотою серед міток для d_j . Показник $(v_{sec}^{(j)} - v_{max}^{(j)})$ трактується як "ступінь позитивного внеску" в конкретній ситуації. Це означає, що якщо більшість класифікаторів дають правильний прогноз разом із класифікатором для d_j , то вплив відповідного класифікатора буде порівняно незначним. Навіть у разі відсутності його прогнозу ансамбль класифікаторів все одно залишиться точним для d_j , за умови відсутності суттєвих суперечностей. Також звернемо увагу, що значення $(v_{sec}^{(j)} - v_{max}^{(j)})$ може приймати від'ємний знак. Для узгодження алгоритму оцінювання індивідуальних внесків, усі правильні

прогнози мають отримувати позитивні значення. Для цього до внеску ($v_{sec}^{(j)} - v_{max}^{(j)}$) додається коригуючий член $v_{max}^{(j)}$, який нормалізує значення, забезпечуючи його додатність, що визначається рівнянням (3.5). Крім того, у $v_{max}^{(j)}$ враховується додаткова корекція ($v_{sec}^{(j)} - v_{c_i(x_j)}^{(j)}$) для збереження відносного порядку внесків, як це показано у рівнянні (3.4).

Якщо ж $c_i(x_j)$ не збігається з y_j , то значення $IC_i^{(j)}$ визначається за рівнянням

$$IC_i^{(j)} = v_{correct}^{(j)} - v_{c_i(x_j)}^{(j)} - v_{max}^{(j)} \quad (3.6)$$

У цьому випадку враховується кількість голосів $v_{correct}^{(j)}$, відданих за правильну мітку d_j . Схожим чином до "ступеня позитивного внеску", "ступінь негативного внеску" обчислюється через різницю між кількістю голосів $v_{correct}^{(j)} - v_{c_i(x_j)}^{(j)}$ за правильну мітку та кількістю голосів за рішенням $c_i(x_j)$. Ця різниця надає кількісну оцінку негативного впливу. Зрештою, інтегруючи рівняння (3.4), (3.5) і (3.6) через рівняння (3.3), отримуємо загальну формулу для обчислення індивідуального внеску класифікатора c_i , яка представлена у рівнянні

$$IC_i = \sum_{j=1}^N (\alpha_{ij}(2v_{max}^{(j)} - v_{c_i(x_j)}^{(j)}) + \beta_{ij}v_{sec}^{(j)} + \theta_{ij}(v_{correct}^{(j)} - v_{c_i(x_j)}^{(j)} - v_{max}^{(j)})) \quad (3.7).$$

, де

$$\alpha_{ij} = \begin{cases} 1 & \text{якщо } c_i(x_j) = y_j \text{ та } c_i(x_j) \text{ знаходиться у групі меньшості;} \\ 0, & \text{інакше} \end{cases}$$

$$\beta_{ij} = \begin{cases} 1, & \text{якщо } c_i(x_j) = y_j \text{ та } c_i(x_j) \text{ знаходиться у групі більшості} \\ 0, & \text{інакше} \end{cases}$$

$$\theta_{ij} = \begin{cases} 1, & \text{якщо } c_i(x_j) \neq y_j \text{ та } c_i(x_j) \\ 0, & \text{інакше} \end{cases}$$

Згідно з рівнянням (3.7), створюється сукупність нейронних мереж, які об'єднуються в ансамбль для виконання завдань аналізу або прогнозування. Такий підхід потребує розроблення ефективного алгоритму для об'єднання

результатів кожної окремої нейронної мережі в рамках ансамблю, що дозволяє підвищити загальну точність моделі. Концепція динамічно усередненої мережі (ДУМ) вводиться через наступне математичне представлення:

$$f_{\text{АМ}} = \sum_{i=1}^n w_i f_i(x) \quad (3.8)$$

, де w_i відповідні компоненти та визначаються відповідно до рівняння:

$$w_i = \frac{c(f_i(x))}{\sum_{i=1}^n c(f_i(x))} \quad (3.9)$$

де $c(f_i(x)) = \begin{cases} f_i(x), & \text{якщо } f_i(x) \geq 0.5 \\ 1 - f_i(x), & \text{інакше} \end{cases}$ у даному контексті $f_{\text{ДУМ}}$ є

середньозваженим значенням виходів ансамблю, яке виступає інтегрованим результатом роботи всієї системи. Формування вагового вектора здійснюється динамічно під час кожного оцінювання виходу ансамблю. Така динамічність дозволяє адаптувати роботу системи до специфічних умов поточного завдання. Замість заздалегідь встановлених статичних ваг цей підхід забезпечує оптимальний перерозподіл впливу окремих модулів залежно від рівня їхньої надійності чи достовірності. Це означає, що кожен елемент вносить вклад пропорційно до своєї важливості, що гарантує пошук оптимального рішення для кожного конкретного випадку.

3.7 Результати

Для демонстрації результатів класифікації було обрано метрики: accuracy, precision, recall, F1 та F2. Було обрано окремі мережі такі як: перцептрон, RBFN, PNN та порівняно з результатами роботи ансамблю нейронних мереж. Результати представлені в таблиці 3.4.

Таблиця 3.3

Матриця помилок

	$y = 1$	$y = 0$
$\hat{y} = 1$	True Positive (TP)	False Positive (FP)
$\hat{y} = 0$	False Negative (FN)	True Negative (TN)

$$accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (3.10)$$

$$precision = \frac{TP}{TP+FP} \quad (3.11)$$

$$recall = \frac{TP}{TP+FN} \quad (3.12)$$

$$F1 = 2 * \frac{Precision*Recall}{Precision+Recall} \quad (3.13)$$

$$F2 = (1 + \beta^2) * \frac{Precision*Recall}{(\beta^2*Precision)+Recall} \quad (3.14)$$

Таблиця 3.4

Результати навчання мереж

Мережа		Accuracy	F2	F1	Presision	Recall
Персептрон	Train	0,2735	0,2819	0,281	0,2709	0,2767
	Validation	0,3306	0,3458	0,3412	0,3392	0,3372
	Test	0,3876	0,3846	0,39	0,3854	0,3876
RBFN	Train	0,38	0,3823	0,384	0,3867	0,3841
	Validation	0,3872	0,3841	0,3824	0,3884	0,3862
	Test	0,3898	0,3878	0,3859	0,381	0,3802
PNN	Train	0,9145	0,9267	0,9263	0,9143	0,9142
	Validation	0,9034	0,9058	0,90	0,8943	0,8857
	Test	0,8552	0,8664	0,8634	0,8512	0,8532
Ансамбль нейронних мереж	Train	0,9902	0,9862	0,9742	0,9548	0,9944
	Validation	0,9754	0,9855	0,9740	0,9555	0,9933
	Test	0,9492	0,9747	0,9488	0,9086	0,9928

3.8 Висновки до розділу 3

Визначено основні ознаки першого, другого та третього ступенів АГ, що дає можливість зменшити обчислювальні витрати на розв'язання задачі діагностики АГ.

Показано, що існуючі методи інтелектуальної діагностики ступеню АГ мають недоліки, що пов'язано з невизначеністю основних ознак першої, другої та третьої ступенів АГ.

Аналіз результатів проведених робіт дозволяє зробити висновок що застосовані топології нейромереж є застарілими та неефективними.

Показано що поєднання кількох прогнозів (ансамблевий підхід) покращує якість навчання та забезпечує якісну класифікацію ступеню АГ.

Запропоновано новий підхід класифікації ступеню АГ на основі використання ансамблевого підходу з використанням критеріїв точності та різноманіття.

РОЗДІЛ 4. ІНФОРМАЦІЙНА ТЕХНОЛОГІЯ ІНТЕЛЕКТУАЛЬНОГО ПРОГНОЗУВАННЯ АТ НА ОСНОВІ БЕЗМАНЖЕТНОГО ВИМІРЮВАННЯ

4.1. Основні сценарії використання інформаційної технології

Головна ціль інформаційної технології, що розроблюється – спростити побудову інтелектуальних прогнозуючих моделей значень АТ з використанням розроблених методів, алгоритмів та моделей. Виходячи з цієї цілі можна виділити наступні основні сценарії використання застосунку:

Сценарій 1 – побудова нової прогнозуючої моделі, з використанням певної вибірки даних:

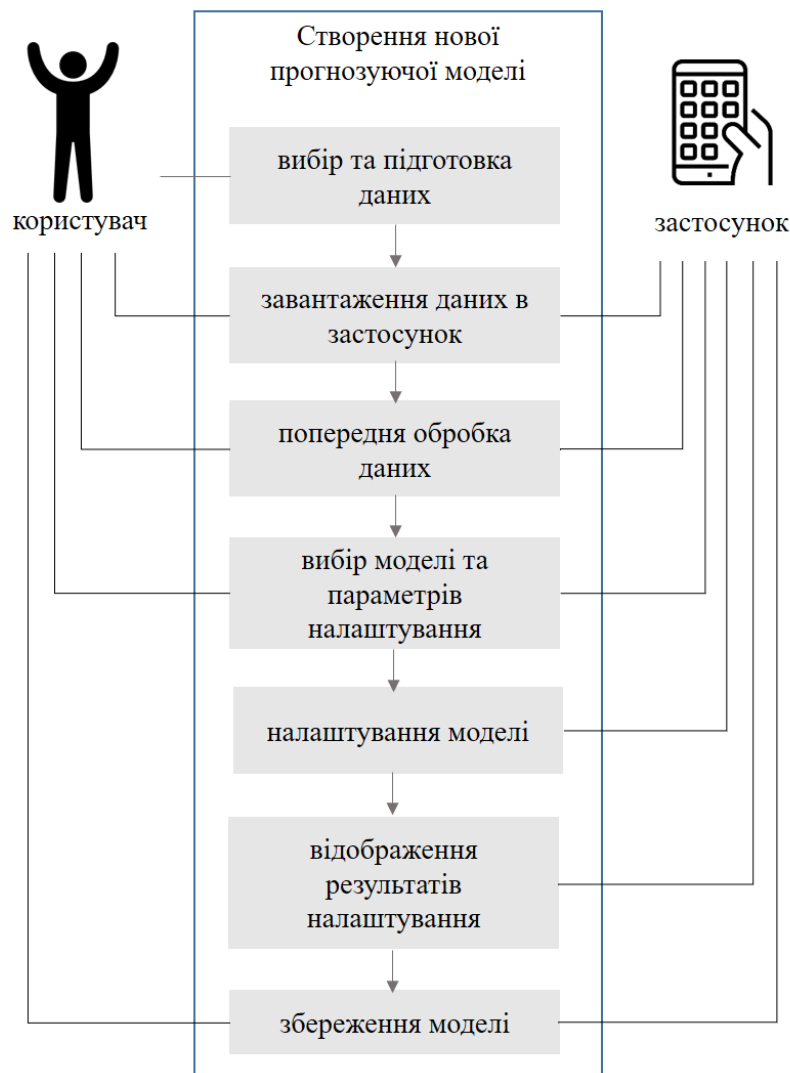


Рисунок 4.1 –

Сценарій 2 – застосування попередньо навченої моделі для здійснення прогнозу на основі свіжих показників:

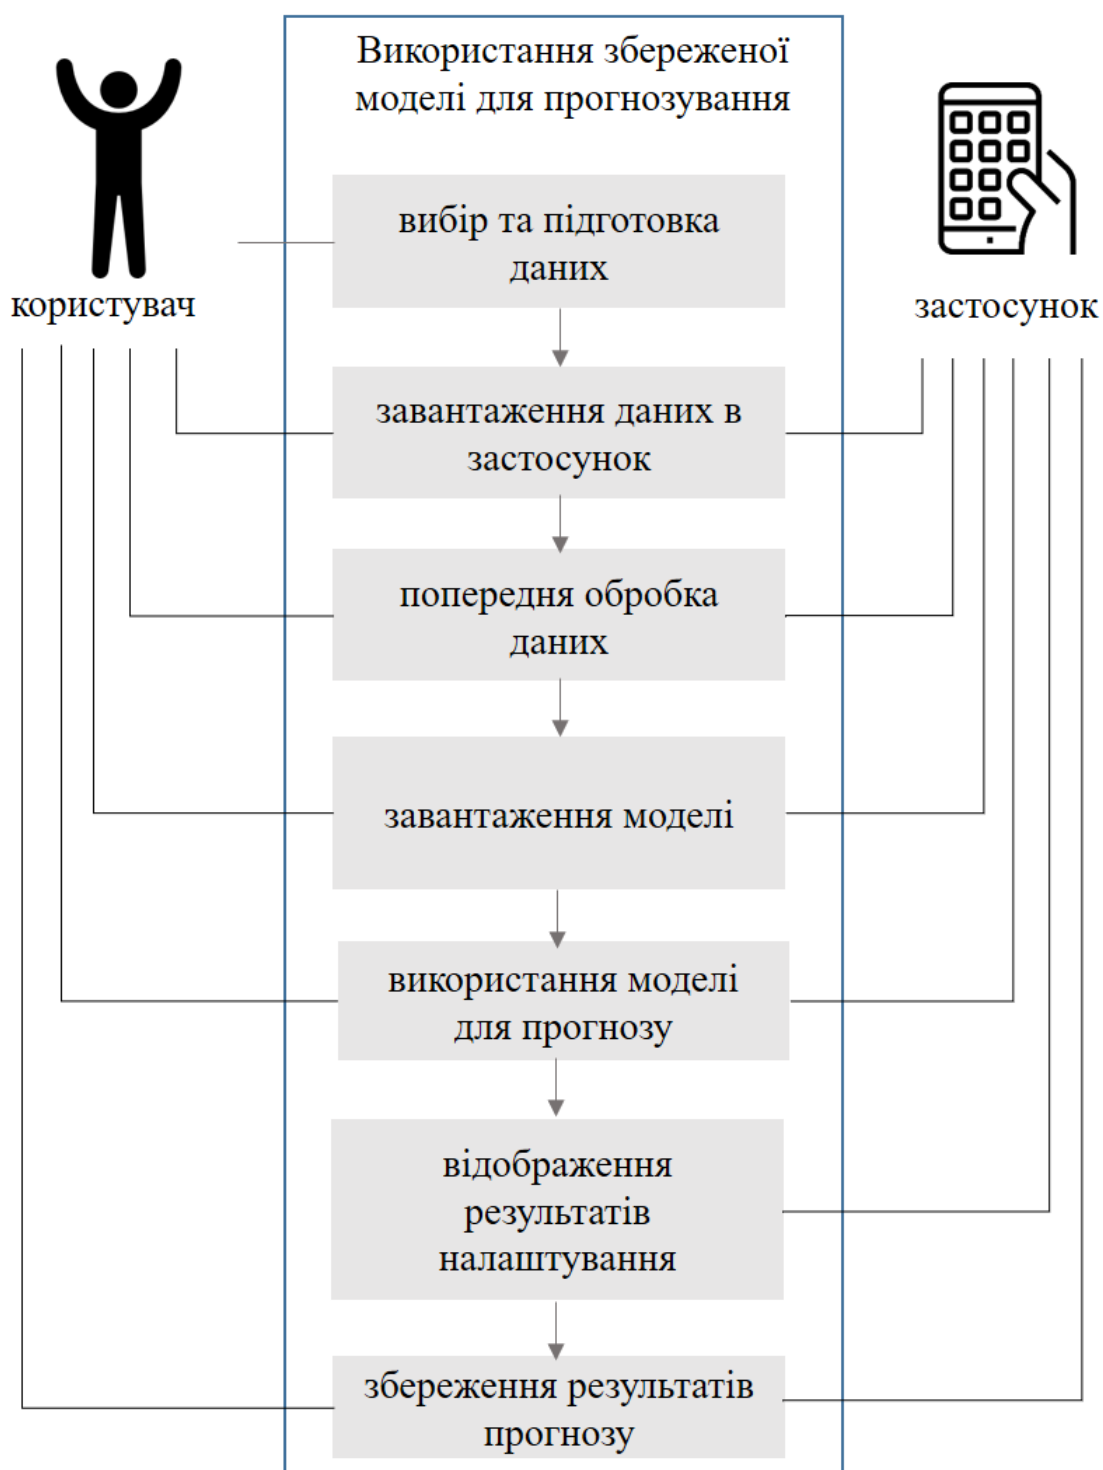


Рисунок 4.2 – Діаграма сценарію «використання збереженої моделі для прогнозування нових даних»

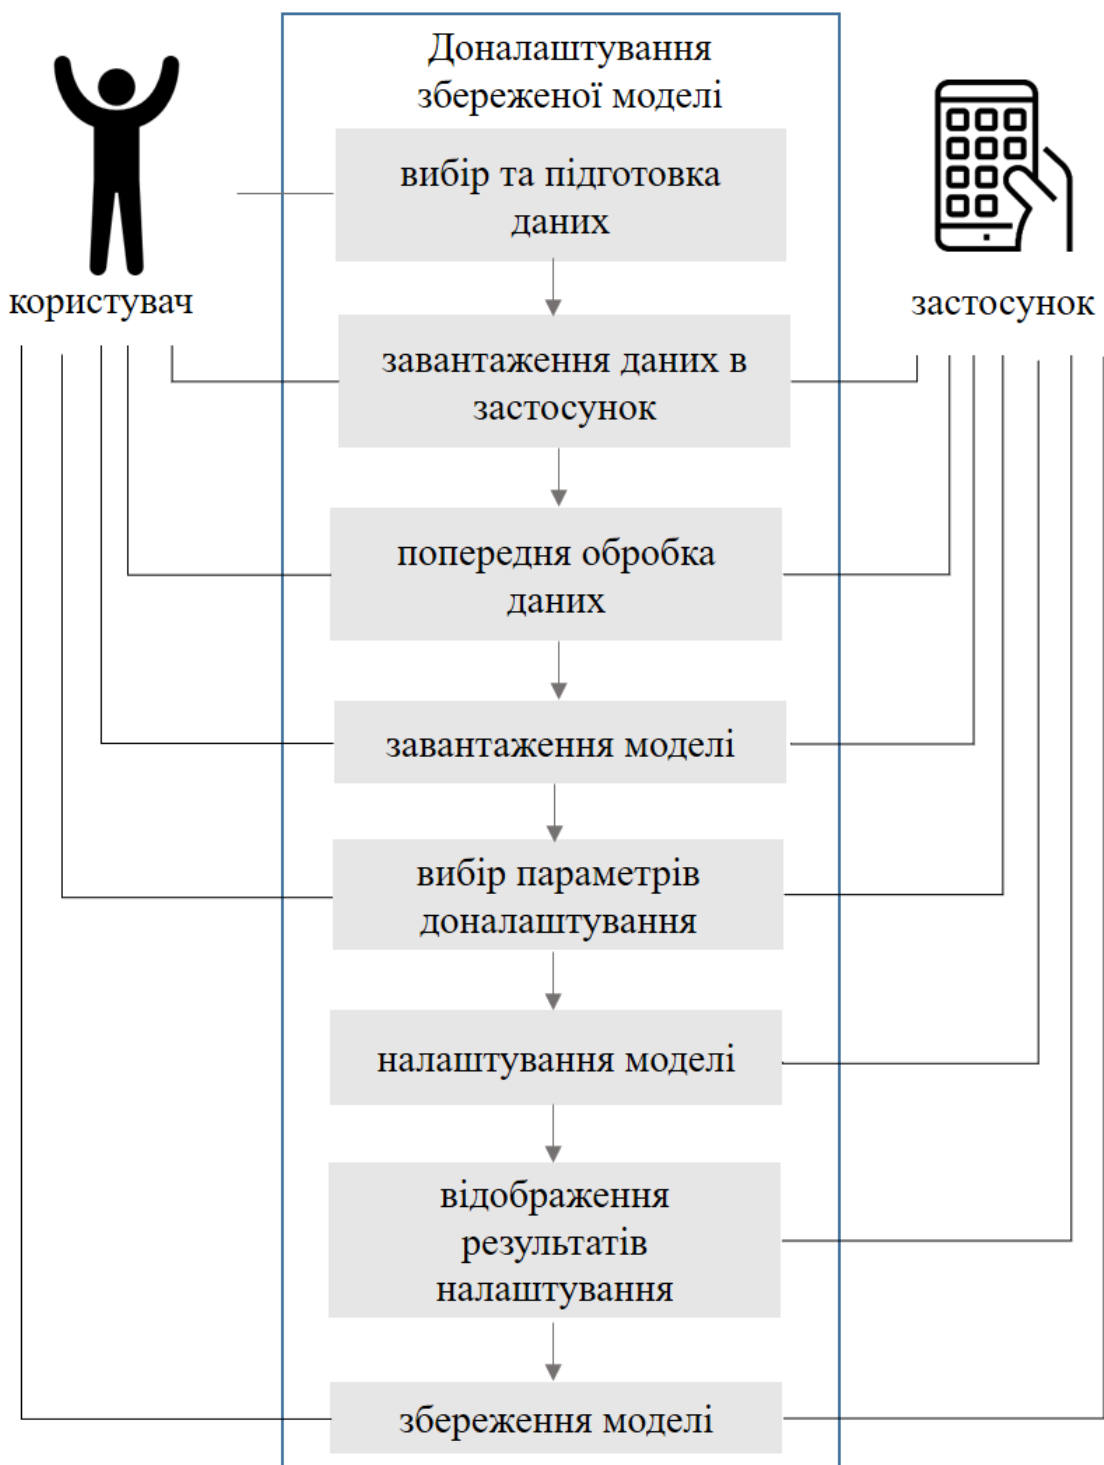
Сценарій 3 – доналаштування збереженої моделі:

Рисунок 4.3 – Діаграма сценарію «доналаштування збереженої моделі»

Сценарій 4 – візуалізація та обробка даних:

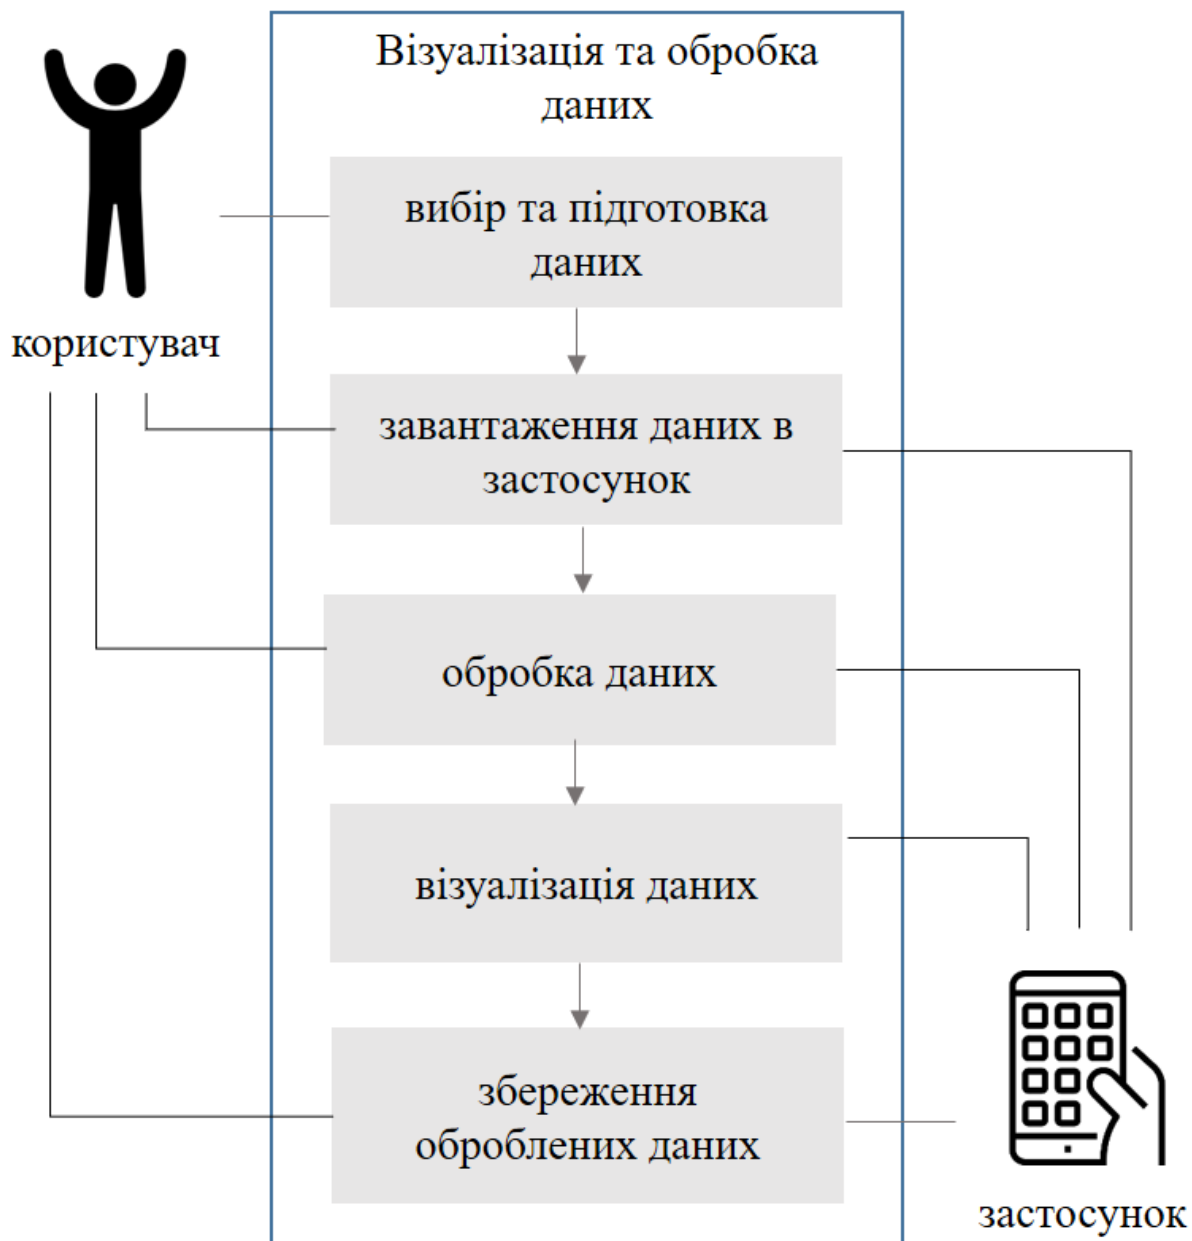


Рисунок 4.4 – Діаграма сценарію «візуалізація та обробка даних»

4.2. Задачі інформаційної технології, їх входи та виходи

Розглянемо список задач, вирішуваних інформаційною технологією, що розробляється, разом з їх входами та виходами.

Задача 1. Імпорт інформації з зовнішнього осередку:




Рисунок 4.5 – Схема входів та виходів задачі «завантаження даних із приладу безманжетного вимірювання тиску»

Задача 2. Візуалізація даних:




Рисунок 4.6 – Схема входів та виходів задачі «Візуалізація даних»

Задача 3. Попередня обробка даних (нормалізація, усунення аномальних збоїв (викидів), очищення даних, пошук відсутніх даних. і т.д.):




Рисунок 4.7 – Схема входів та виходів задачі «попередня обробка даних»

Задача 4. Прогнозування значень АТ:

4.1. Побудова прогнозуючої моделі.

4.2. Використання прогнозуючої моделі для отримання прогнозу.

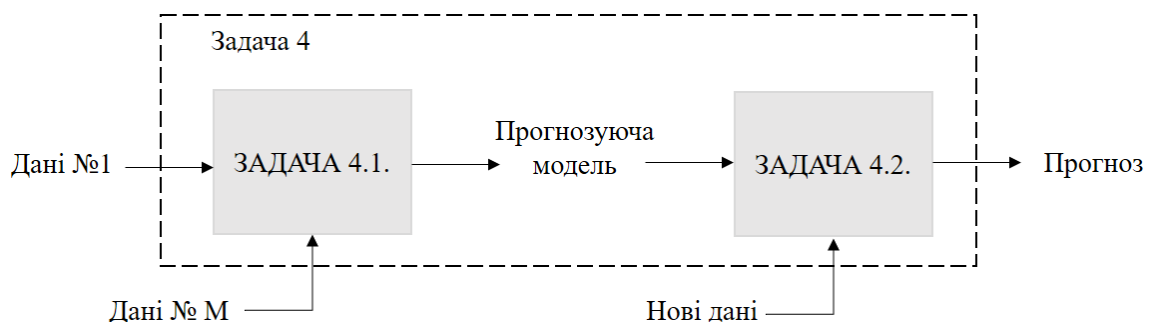


Рисунок 4.8 – Схема входів та виходів задачі «прогнозування артеріального тиску»

Задача 5. Завантажити інформацію на зовнішній пристрій (як документ):




Рисунок 4.9 – Схема входів та виходів задачі «завантаження інформації у зовнішній осередок»

Загальна схема взаємодії усіх задач виглядає наступним чином:

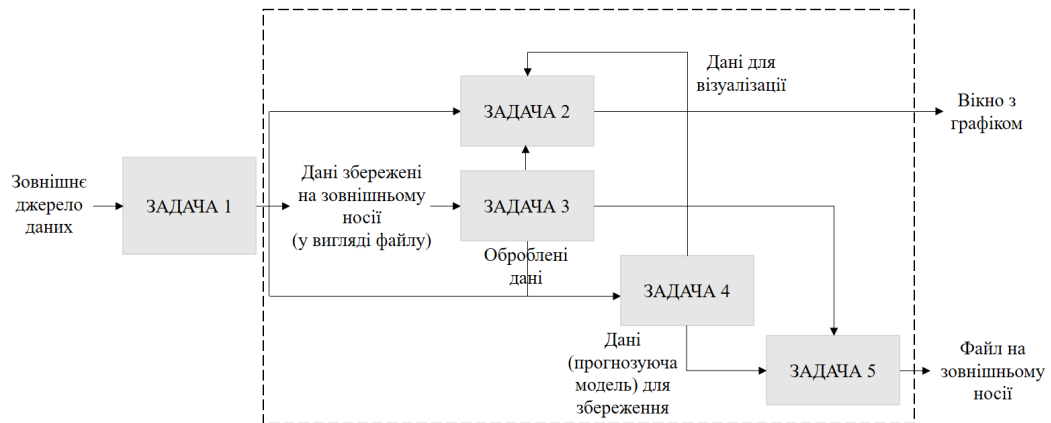


Рисунок 4.10 – Загальна схема взаємодії усіх задач за стосунку

4.3. Розробка архітектури інформаційної технології: прогнозування артеріального тиску

Функціональна структура інформаційної технології прогнозування артеріального тиску, що відповідає описаним вимогам та сценаріям використання має наступний вигляд:

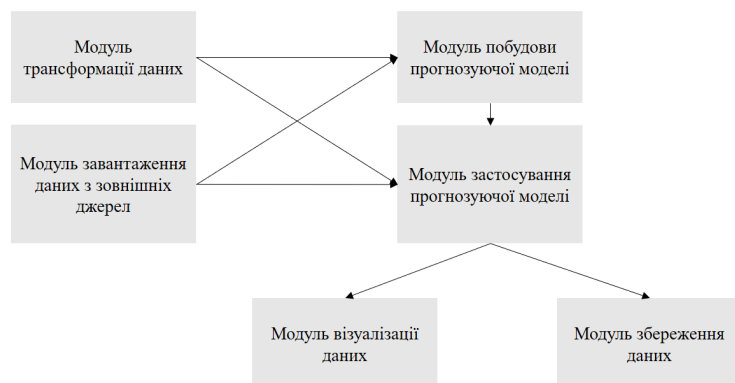


Рисунок 4.11 – Функціональна структура інформаційної технології прогнозування АТ

Інформаційна модель структурно визначається з низки ключових функціональних модулів, кожен із яких виконує певну роль у процесі збору, обробки та аналізу даних. Зокрема, її архітектура включає такі компоненти:

- Модуль імпорту інформації із зовнішніх осередків. Він забезпечує завантаження інформації з різноманітних осередків у різних форматах (структурованих та неструктурованих), з подальшим перетворенням до внутрішнього стандарту для подальшої обробки.

- Модуль трансформації даних. Основна функція цього компонента полягає в реалізації широкого спектра методів обробки даних, що перебувають у внутрішньому форматі, а також у приведенні їх до формату, зручного для аналітичного аналізу.

- Модуль розробки прогнозуючої моделі. Цей модуль виконує імплементацію алгоритмів та математичних моделей, спрямованих на створення інтелектуальних прогнозних систем, адаптованих для аналізу заданих наборів даних.

- Модуль застосування прогнозної моделі. Передбачає практичне використання розробленої моделі для аналізу конкретних вибірок інформації, пов'язаних із дослідженням станів артеріального тиску або інших параметрів системи.

- Модуль графічного представлення інформації. Забезпечує графічне представлення вхідних наборів даних на основі визначених параметрів візуалізації, що дозволяє підвищити наочність аналізу результатів.

- Модуль експорту інформації. Виконує функцію обробки опрацьованої інформації з внутрішнього в заданий зовнішній формат для подальшого збереження в обраних зовнішніх носіях або базах даних.

Таким чином, кожен з перелічених модулів виконує критично важливу функцію у загальній інформаційній системі, забезпечуючи її цілісність, ефективність та гнучкість.

Взаємодія та інтеграція розробленої ІТ з інформаційною системою користувача відбувається згідно з наступною структурною схемою взаємодії:

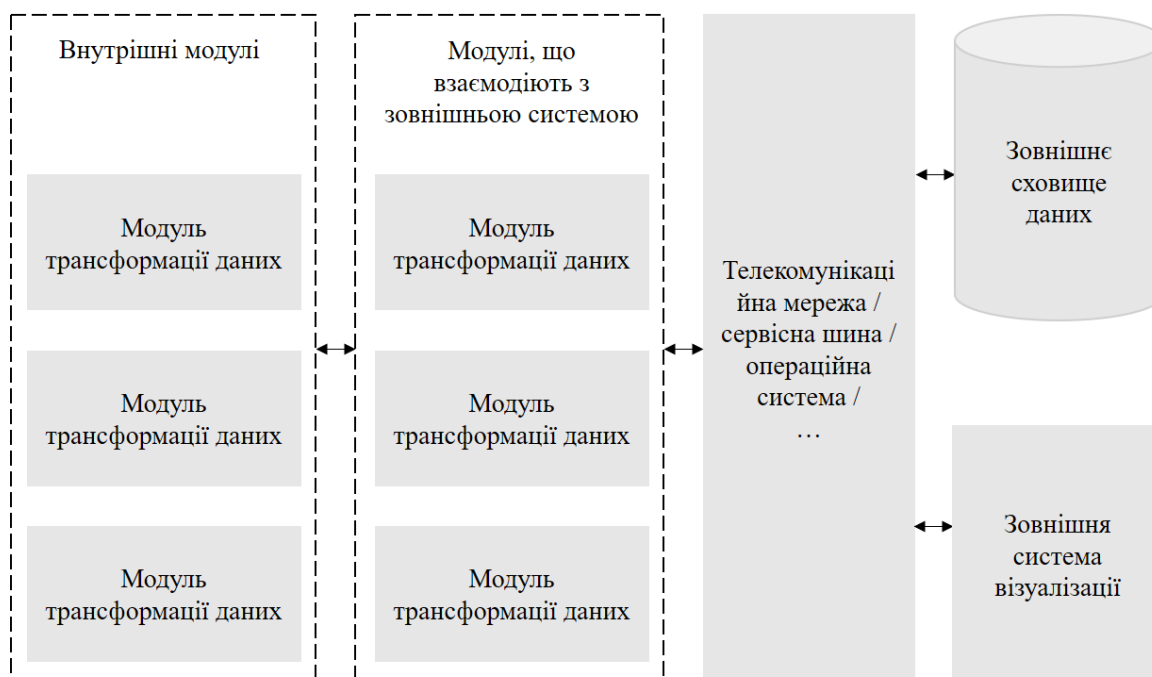


Рисунок 4.12 – Структурна схема взаємодії та інтеграції модулів ІТ з зовнішньою інформаційною системою

4.4 Висновки до розділу 4

Сформульовано можливі сценарії для прогнозування артеріального тиску на основі безманжетного вимірювання та на їх основі розроблено інформаційну технологію інтелектуального прогнозування.

Запропонована технологія може бути використана для безперервної діагностики стану серцево-судинної системи пацієнта, персоналізованого прогнозування ризиків артеріальної гіпертензії з індивідуальним прогностичним горизонтом, оперативного сповіщення користувачів про можливі ризики та подальші необхідні дії.

ВИСНОВКИ

У дисертаційній роботі вирішується актуальна проблема класифікації ступеню артеріальної гіпертензії та прогнозування артеріального тиску, що дозволяє запобігти гострим станам як інфаркт або інсульт. Поставлені в дисертаційній роботі задачі виконані в повному обсязі.

Запропоновано підхід до попередньої обробки даних безманжетного вимірювання АТ на основі використання алгоритмів усунення аномальних викидів та очищення даних, що дає можливість покращити результати прогнозування АТ у хворих.

Було отримано наступні наукові результати:

- вперше запропоновано метод для обробки даних артеріального тиску у хворих, який відрізняється тим, що на основі методів безманжетного вимірювання здійснює попередню обробку отриманих даних та подальше прогнозування на основі використання гібридних рекурентних нейронних мереж, горизонт прогнозу яких адаптовано під поточний стан пацієнта, що дає можливість знизити імовірність виникнення інсульту або інфаркту у хворих в середньому на 10%;

- удосконалено метод вирішення задачі класифікації та знижено обчислювальні витрати при машинному навчанні гібридних нейронних мереж за рахунок визначення найбільш впливових ознак артеріальної гіпертензії для різних ступенів захворювання, які крім загальних ознак (анамнез, результати огляду лікаря, результати аналізів крові, сечі, вимірювання артеріального тиску) включають результати обробки ЕКГ, ЕхоКГ;

- розроблено метод структурно-параметричного синтезу гібридної нейронної мережі для розв'язання задачі класифікації ступеня артеріальної гіпертензії, який відрізняється тим, що гібридна нейронна мережа будується на основі створення беггінг-ансамблю інтелектуальних класифікаторів, включених в ансамбль за критеріями точності та різноманіття, що дозволяє підвищити точність класифікації.

Було отримано наступні практичні результати:

- розроблені інтелектуальні методи та алгоритми прогнозування значень артеріального тиску на основі використання безманжетного вимірювання, що дозволило підвищити рівень запобігання інсультів та інфарктів у хворих;
- розроблено новий підхід до діагностування ступеню артеріальної гіпертензії у хворих;
- використання запропонованих методів та алгоритмів у ДУ «Національний науковий центр імені академіка М.Д. Стражеска», що дозволило підвищити рівень запобігання інсультів і інфарктів у хворих.

СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ

1. Kolomoiets, S. (2024). Concepts of creating an intelligent medical diagnostic system to assist in the work and training of doctors based on artificial intelligence. *Information Technology and Society*, (5 (11)), 28–33. <https://doi.org/10.32689/maup.it.2023.5.4> .
2. Kreutz, R., Brunström, M., & Burnier, M. (2024). European Society of Hypertension clinical practice guidelines for the management of arterial hypertension. *European Journal of Internal Medicine*, (Vol. 126), 1–15. <https://doi.org/10.1016/j.ejim.2024.05.033> .
3. The top 10 causes of death. World Health Organization (WHO). (2024). World Health Organization (WHO). <https://www.who.int/news-room/fact-sheets/detail/the-top-10-causes-of-death> .
4. Серцево-судинні захворювання — головна причина смерті українців. Висновки з дослідження Глобального тягара хвороб у 2019 році. (2021). Центр Громадського Здоров'я МОЗ України. <https://phc.org.ua/news/sercevo-sudinni-zakhvoryuvannya-golovna-prichina-smerti-ukrainciv-visnovki-z-doslidzhennya> .
5. Deaths from cardiovascular disease surged 60% globally over the last 30 years: Report. (2023). World Heart Federation. <https://world-heart-federation.org/news/deaths-from-cardiovascular-disease-surged-60-globally-over-the-last-30-years-report/> .
6. Смертність в Україні 2018-2020. (б. д.). Український Центр Суспільних Даних. <https://socialdata.org.ua/projects/mortality/> .
7. Lam, S., Liu, H., Jian, Z., Settels, J., & Bohringer, C. (2021). Intraoperative Invasive Blood Pressure Monitoring and the Potential Pitfalls of Invasively Measured Systolic Blood Pressure. *Cureus*. <https://doi.org/10.7759/cureus.17610> .
8. Fukushima, H., Kawanaka, H., Bhuiyan, M. S., & Oguri, K. (2013). Cuffless blood pressure estimation using only photoplethysmography based on cardiovascular parameters. *Annual International Conference of the IEEE Engineering in Medicine and Biology Society. IEEE Engineering in Medicine and Biology Society. Annual*

- International Conference, 2013, 2132–2135. <https://doi.org/10.1109/EMBC.2013.6609955> .
9. Schoettker, P., Degott, J., Hofmann, G., Proença, M., Bonnier, G., Lemkaddem, A., Lemay, M., Schorer, R., Christen, U., Knebel, J. F., Wuerzner, A., Burnier, M., & Wuerzner, G. (2020). Blood pressure measurements with the OptiBP smartphone app validated against reference auscultatory measurements. *Scientific reports*, 10(1), 17827. <https://doi.org/10.1038/s41598-020-74955-4> .
 10. Nitzan, M., Adar, Y., Hoffman, E., Shalom, E., Engelberg, S., Ben-Dov, I. Z., & Bursztyn, M. (2013). Comparison of systolic blood pressure values obtained by photoplethysmography and by Korotkoff sounds. *Sensors (Basel, Switzerland)*, 13(11), 14797–14812. <https://doi.org/10.3390/s131114797> .
 11. Thomsen, K. K., Kouz, K., & Saugel, B. (2023). Pulse wave analysis: basic concepts and clinical application in intensive care medicine. *Current opinion in critical care*, 29(3), 215–222. <https://doi.org/10.1097/MCC.0000000000001039> .
 12. Charlton, P. H., Kyriaco, P. A., Mant, J., Marozas, V., Chowienczyk, P., & Alastruey, J. (2022). Wearable Photoplethysmography for Cardiovascular Monitoring. *Proceedings of the IEEE. Institute of Electrical and Electronics Engineers*, 110(3), 355–381. <https://doi.org/10.1109/JPROC.2022.3149785> .
 13. Hofmann, G., Proença, M., Degott, J., Bonnier, G., Lemkaddem, A., Lemay, M., Schorer, R., Christen, U., Knebel, J. F., & Schoettker, P. (2023). A novel smartphone app for blood pressure measurement: a proof-of-concept study against an arterial catheter. *Journal of clinical monitoring and computing*, 37(1), 249–259. <https://doi.org/10.1007/s10877-022-00886-2> .
 14. Jonathan, E., & Leahy, M. (2010). Investigating a smartphone imaging unit for photoplethysmography. *Physiological measurement*, 31(11), N79–N83. <https://doi.org/10.1088/0967-3334/31/11/N01> .
 15. Liu, Z. D., Li, Y., Zhang, Y. T., Zeng, J., Chen, Z. X., Cui, Z. W., Liu, J. K., & Miao, F. (2023). Cuffless Blood Pressure Measurement Using Smartwatches: A Large-Scale Validation Study. *IEEE journal of biomedical and health informatics*, 27(9), 4216–4227. <https://doi.org/10.1109/JBHI.2023.3278168> .

16. Qin, C., Wang, X., Xu, G., & Ma, X. (2022). Advances in Cuffless Continuous Blood Pressure Monitoring Technology Based on PPG Signals. *BioMed research international*, 2022, 8094351. <https://doi.org/10.1155/2022/8094351> .
17. Bird, K., Chan, G., Lu, H., Greeff, H., Allen, J., Abbott, D., Menon, C., Lovell, N. H., Howard, N., Chan, W. S., Fletcher, R. R., Alian, A., Ward, R., & Elgendi, M. (2020). Assessment of Hypertension Using Clinical Electrocardiogram Features: A First-Ever Review. *Frontiers in medicine*, 7, 583331. <https://doi.org/10.3389/fmed.2020.583331> .
18. Landry, C., & Mukkamala, R. (2023). Current evidence suggests that estimating blood pressure from convenient ECG waveforms alone is not viable. *Journal of electrocardiology*, 81, 153–155. <https://doi.org/10.1016/j.jelectrocard.2023.09.001>
19. Gordon J. W. (1877). Certain Molar Movements of the Human Body produced by the Circulation of the Blood. *Journal of anatomy and physiology*, 11(Pt 3), 533–536.
20. Kim, C. S., Ober, S. L., McMurtry, M. S., Finegan, B. A., Inan, O. T., Mukkamala, R., & Hahn, J. O. (2016). Ballistocardiogram: Mechanism and Potential for Unobtrusive Cardiovascular Health Monitoring. *Scientific reports*, 6, 31297. <https://doi.org/10.1038/srep31297> .
21. Shin, S., Mousavi, A., Lyle, S., Jang, E., Yousefian, P., Mukkamala, R., Jang, D. G., Kwon, U. K., Kim, Y. H., & Hahn, J. O. (2022). Posture-Dependent Variability in Wrist Ballistocardiogram-Photoplethysmogram Pulse Transit Time: Implication to Cuff-Less Blood Pressure Tracking. *IEEE transactions on bio-medical engineering*, 69(1), 347–355. <https://doi.org/10.1109/TBME.2021.3094200> .
22. Ward L. C. (2021). Electrical Bioimpedance: From the Past to the Future. *Journal of electrical bioimpedance*, 12(1), 1–2. <https://doi.org/10.2478/joeb-2021-0001> .
23. Bera T. K. (2014). Bioelectrical Impedance Methods for Noninvasive Health Monitoring: A Review. *Journal of medical engineering*, 2014, 381251. <https://doi.org/10.1155/2014/381251> .
24. Soukup, L., Hruskova, J., Jurak, P., Halamek, J., Zavodna, E., Viscor, I., Matejkova, M., & Vondra, V. (2019). Comparison of noninvasive pulse transit time

- determined from Doppler aortic flow and multichannel bioimpedance plethysmography. *Medical & biological engineering & computing*, 57(5), 1151–1158. <https://doi.org/10.1007/s11517-018-01948-x>.
25. Patterson R. P. (1989). Fundamentals of impedance cardiography. *IEEE engineering in medicine and biology magazine : the quarterly magazine of the Engineering in Medicine & Biology Society*, 8(1), 35–38. <https://doi.org/10.1109/51.32403>.
 26. Wong, M. M., Pickwell-Macpherson, E., & Zhang, Y. T. (2009). Impedance cardiography for cuffless and non-invasive measurement of systolic blood pressure. *Annual International Conference of the IEEE Engineering in Medicine and Biology Society. IEEE Engineering in Medicine and Biology Society. Annual International Conference*, 2009, 800–802. <https://doi.org/10.1109/IEMBS.2009.5333521>.
 27. Sharman, D. L., Gomes, C. P., & Rutherford, J. P. (2004). Improvement in blood pressure control with impedance cardiography-guided pharmacologic decision making. *Congestive heart failure (Greenwich, Conn.)*, 10(1), 54–58. <https://doi.org/10.1111/j.1527-5299.2004.03226.x>.
 28. Lee, K., & Yoo, H. J. (2021). Simultaneous Electrical Bio-Impedance Plethysmography at Different Body Parts: Continuous and Non-Invasive Monitoring of Pulse Wave Velocity. *IEEE transactions on biomedical circuits and systems*, 15(5), 1027–1038. <https://doi.org/10.1109/TBCAS.2021.3115021>.
 29. Kireev, D., Sel, K., Ibrahim, B., Kumar, N., Akbari, A., Jafari, R., & Akinwande, D. (2022). Continuous cuffless monitoring of arterial blood pressure via graphene bioimpedance tattoos. *Nature nanotechnology*, 17(8), 864–870. <https://doi.org/10.1038/s41565-022-01145-w>.
 30. Inan, O. T., Migeotte, P. F., Park, K. S., Etemadi, M., Tavakolian, K., Casanella, R., Zanetti, J., Tank, J., Funtova, I., Prisk, G. K., & Di Rienzo, M. (2015). Ballistocardiography and seismocardiography: a review of recent advances. *IEEE journal of biomedical and health informatics*, 19(4), 1414–1427. <https://doi.org/10.1109/JBHI.2014.2361732>.

31. Das, M., Choudhary, T., Sharma, L.N., & Bhuyan, M.K. (2020). Noninvasive Accelerometric Approach for Cuffless Continuous Blood Pressure Measurement. *IEEE Transactions on Instrumentation and Measurement*, 70, 1-9.
32. Sørensen, K., Verma, A.K., Blaber, A.P., Zanetti, J.M., Schmidt, S.E., Struijk, J.J., & Tavakolian, K. (2017). Challenges in using seismocardiography for blood pressure monitoring. *2017 Computing in Cardiology (CinC)*, 1-4.
33. Shandhi, M. M. H., Fan, J., Heller, J. A., Etemadi, M., Klein, L., & Inan, O. T. (2022). Estimation of Changes in Intracardiac Hemodynamics Using Wearable Seismocardiography and Machine Learning in Patients With Heart Failure: A Feasibility Study. *IEEE transactions on bio-medical engineering*, 69(8), 2443–2455. <https://doi.org/10.1109/TBME.2022.3147066> .
34. Santucci, F., Nobili, M., Presti, D. L., Massaroni, C., Setola, R., Schena, E., & Oliva, G. (2023). Waveform Similarity Analysis Using Graph Mining for the Optimization of Sensor Positioning in Wearable Seismocardiography. *IEEE transactions on bio-medical engineering*, 70(10), 2788–2798. <https://doi.org/10.1109/TBME.2023.3264940> .
35. Nelson, M. R., Stepanek, J., Cevette, M., Covalciuc, M., Hurst, R. T., & Tajik, A. J. (2010). Noninvasive measurement of central vascular pressures with arterial tonometry: clinical revival of the pulse pressure waveform?. *Mayo Clinic proceedings*, 85(5), 460–472. <https://doi.org/10.4065/mcp.2009.0336> .
36. Pressman, G. L., & Newgard, P. M. (1963). A Transducer For The Continuous External Measurement Of Arterial Blood Pressure. *IEEE transactions on bio-medical engineering*, 10, 73–81. <https://doi.org/10.1109/tbmel.1963.4322794> .
37. Kemmotsu, O., Ueda, M., Otsuka, H., Yamamura, T., Winter, D. C., & Eckerle, J. S. (1991). Arterial tonometry for noninvasive, continuous blood pressure monitoring during anesthesia. *Anesthesiology*, 75(2), 333–340. <https://doi.org/10.1097/00000542-199108000-00023> .
38. Mishra, S., Mohanty, S., & Ramadoss, A. (2022). Functionality of Flexible Pressure Sensors in Cardiovascular Health Monitoring: A Review. *ACS sensors*, 7(9), 2495–2520. <https://doi.org/10.1021/acssensors.2c00942> .

39. He, F., You, X., Wang, W., Bai, T., Xue, G., & Ye, M. (2021). Recent Progress in Flexible Microstructural Pressure Sensors toward Human-Machine Interaction and Healthcare Applications. *Small methods*, 5(3), e2001041. <https://doi.org/10.1002/smt.202001041>.
40. Zhao, L., Liang, C., Huang, Y., Zhou, G., Xiao, Y., Ji, N., Zhang, Y. T., & Zhao, N. (2023). Emerging sensing and modeling technologies for wearable and cuffless blood pressure monitoring. *NPJ digital medicine*, 6(1), 93. <https://doi.org/10.1038/s41746-023-00835-6>.
41. Kim, J., Chou, E. F., Le, J., Wong, S., Chu, M., & Khine, M. (2019). Soft Wearable Pressure Sensors for Beat-to-Beat Blood Pressure Monitoring. *Advanced healthcare materials*, 8(13), e1900109. <https://doi.org/10.1002/adhm.201900109>.
42. Chowdhury, A. H., Jafarizadeh, B., Baboukani, A. R., Pala, N., & Wang, C. (2023). Monitoring and analysis of cardiovascular pulse waveforms using flexible capacitive and piezoresistive pressure sensors and machine learning perspective. *Biosensors & bioelectronics*, 237, 115449. <https://doi.org/10.1016/j.bios.2023.115449>.
43. Rachim, V. P., Kang, S., Baek, J.-H., & Park, S.-M. (2021). Unobtrusive, Cuffless Blood Pressure Monitoring Using a Soft Polymer Sensor Array With Flexible Hybrid Electronics. *IEEE Sensors Journal*, 21(8), 10132–10142. <https://doi.org/10.1109/jsen.2021.3059864>.
44. Luo, N., Dai, W., Li, C., Zhou, Z., Lu, L., Poon, C. C. Y., Chen, S.-C., Zhang, Y., & Zhao, N. (2015). Flexible Piezoresistive Sensor Patch Enabling Ultralow Power Cuffless Blood Pressure Measurement. *Advanced Functional Materials*, 26(8), 1178–1187. <https://doi.org/10.1002/adfm.201504560>.
45. Weber, S., Strommenger, D., Kertzsch, U., & Affeld, K. (2012). Continuous blood pressure measurement with ultrasound. *Biomedizinische Technik. Biomedical engineering*, 57 Suppl 1, /j/bmte.2012.57.issue-s1-O/bmt-2012-4108/bmt-2012-4108.xml. <https://doi.org/10.1515/bmt-2012-4108>.
46. Martinez-Ríos, E., Montesinos, L., Alfaro-Ponce, M., & Pecchia, L. (2021). A review of machine learning in hypertension detection and blood pressure

- estimation based on clinical and physiological data. *Biomedical Signal Processing and Control*, 68, 102813. <https://doi.org/10.1016/j.bspc.2021.102813> .
47. Pinsky M. R. (2003). Hemodynamic monitoring in the intensive care unit. *Clinics in chest medicine*, 24(4), 549–560. [https://doi.org/10.1016/s0272-5231\(03\)00095-9](https://doi.org/10.1016/s0272-5231(03)00095-9) .
 48. Araghi, A., Bander, J. J., & Guzman, J. A. (2006). Arterial blood pressure monitoring in overweight critically ill patients: invasive or noninvasive?. *Critical care (London, England)*, 10(2), R64. <https://doi.org/10.1186/cc4896> .
 49. Mukkamala, R., Hahn, J. O., Inan, O. T., Mestha, L. K., Kim, C. S., Töreyn, H., & Kyal, S. (2015). Toward Ubiquitous Blood Pressure Monitoring via Pulse Transit Time: Theory and Practice. *IEEE transactions on bio-medical engineering*, 62(8), 1879–1901. <https://doi.org/10.1109/TBME.2015.2441951> .
 50. Masum, S., Chiverton, J.P., Liu, Y., Vuksanovic, B. (2019). Investigation of Machine Learning Techniques in Forecasting of Blood Pressure Time Series Data. In: Bramer, M., Petridis, M. (eds) *Artificial Intelligence XXXVI. SGAI 2019. Lecture Notes in Computer Science()*, vol 11927. Springer, Cham. https://doi.org/10.1007/978-3-030-34885-4_21 .
 51. Wang, R., Jia, W., Mao, Z. H., Sciabassi, R. J., & Sun, M. (2014). Cuff-Free Blood Pressure Estimation Using Pulse Transit Time and Heart Rate. *International conference on signal processing proceedings. International Conference on Signal Processing*, 2014, 115–118. <https://doi.org/10.1109/ICOSP.2014.7014980> .
 52. Slapničar, G., Mlakar, N., & Luštrek, M. (2019). Blood Pressure Estimation from Photoplethysmogram Using a Spectro-Temporal Deep Neural Network. *Sensors (Basel, Switzerland)*, 19(15), 3420. <https://doi.org/10.3390/s19153420> .
 53. Sun, S., Bresch, E., Muehlsteff, J., Schmitt, L., Long, X., Bezemer, R., Paulussen, I., Noordergraaf, G. J., & Aarts, R. M. (2023). Systolic blood pressure estimation using ECG and PPG in patients undergoing surgery. *Biomedical Signal Processing and Control*, 79, 104040. <https://doi.org/10.1016/j.bspc.2022.104040> .
 54. Leitner, J., Chiang, P. H., & Dey, S. (2022). Personalized Blood Pressure Estimation Using Photoplethysmography: A Transfer Learning Approach. *IEEE*

- journal of biomedical and health informatics, 26(1), 218–228.
<https://doi.org/10.1109/JBHI.2021.3085526> .
55. Chiang, P. H., Wong, M., & Dey, S. (2021). Using Wearables and Machine Learning to Enable Personalized Lifestyle Recommendations to Improve Blood Pressure. *IEEE journal of translational engineering in health and medicine*, 9, 2700513. <https://doi.org/10.1109/JTEHM.2021.3098173> .
 56. Wang, D., Yang, X., Wu, J., & Wang, W. (2023). Personalized Modeling of Blood Pressure with Photoplethysmography: an Error-Feedback Incremental Support Vector Regression Model. *IEEE Internet of Things Journal*, 1. <https://doi.org/10.1109/jiot.2023.3290557> .
 57. Pediaditis, M., Spanakis, E. G., Zacharakis, G., & Sakkalis, V. (2021). Cuff-less blood pressure estimation using wrist photoplethysmography. *Annual International Conference of the IEEE Engineering in Medicine and Biology Society. IEEE Engineering in Medicine and Biology Society. Annual International Conference*, 2021, 7356–7359. <https://doi.org/10.1109/EMBC46164.2021.9629544> .
 58. Liu, Z. D., Liu, J. K., Wen, B., He, Q. Y., Li, Y., & Miao, F. (2018). Cuffless Blood Pressure Estimation Using Pressure Pulse Wave Signals. *Sensors (Basel, Switzerland)*, 18(12), 4227. <https://doi.org/10.3390/s18124227> .
 59. Bard, D. M., Joseph, J. I., & van Helmond, N. (2019). Cuff-Less Methods for Blood Pressure Telemonitoring. *Frontiers in cardiovascular medicine*, 6, 40. <https://doi.org/10.3389/fcvm.2019.00040> .
 60. Khalid, S. G., Zhang, J., Chen, F., & Zheng, D. (2018). Blood Pressure Estimation Using Photoplethysmography Only: Comparison between Different Machine Learning Approaches. *Journal of healthcare engineering*, 2018, 1548647. <https://doi.org/10.1155/2018/1548647> .
 61. Eom, H., Lee, D., Han, S., Hariyani, Y. S., Lim, Y., Sohn, I., Park, K., & Park, C. (2020). End-to-End Deep Learning Architecture for Continuous Blood Pressure Estimation Using Attention Mechanism. *Sensors (Basel, Switzerland)*, 20(8), 2338. <https://doi.org/10.3390/s20082338> .

- 62.Liu, Z., Miao, F., Wang, R., Liu, J., Wen, B., & Li, Y. (2019). Cuff-less Blood Pressure Measurement Based on Deep Convolutional Neural Network. Annual International Conference of the IEEE Engineering in Medicine and Biology Society. IEEE Engineering in Medicine and Biology Society. Annual International Conference, 2019, 3775–3778. <https://doi.org/10.1109/EMBC.2019.8856588> .
- 63.Alexandropoulos, S.-A. N., Kotsiantis, S. B., & Vrahatis, M. N. (2019). Data preprocessing in predictive data mining. The Knowledge Engineering Review, 34. <https://doi.org/10.1017/s026988891800036x> .
- 64.García, S., Luengo, J., & Herrera, F. (2015). Data preprocessing in data mining (Vol. 72, pp. 59-139). Cham, Switzerland: Springer International Publishing.
- 65.Huang, Y., Milani, M., & Chiang, F. (2020). Privacy-aware data cleaning-as-a-service. Information Systems, 94, 101608.
- 66.Ruan, S., Li, R., Bao, J., He, T., & Zheng, Y. (2018, April). Cloudtp: A cloud-based flexible trajectory preprocessing framework. In 2018 IEEE 34th international conference on data engineering (ICDE) (pp. 1601-1604). IEEE.
- 67.Zheng, A., & Casari, A. (2018). Feature engineering for machine learning: principles and techniques for data scientists. " O'Reilly Media, Inc."
- 68.Alpaydin, E. (2020). Introduction to machine learning. MIT press.
- 69.Box, G. E., & Cox, D. R. (1964). An analysis of transformations. Journal of the Royal Statistical Society Series B: Statistical Methodology, 26(2), 211-243.
- 70.Han, J., Kamber, M., & Pei, J. (2011). Data Mining : Concepts and Techniques 3rd edition Ed. 3.
- 71.Gupta, V., & Hewett, R. (2019, November). Adaptive normalization in streaming data. In Proceedings of the 3rd International Conference on Big Data Research (pp. 12-17).
- 72.Ogasawara, E., Martinez, L. C., De Oliveira, D., Zimbrão, G., Pappa, G. L., & Mattoso, M. (2010, July). Adaptive normalization: A novel data normalization approach for non-stationary time series. In The 2010 International Joint Conference on Neural Networks (IJCNN) (pp. 1-8). IEEE.

73. Tawakuli, A., Kaiser, D., & Engel, T. (2022, November). Transforming iot data preprocessing: A holistic, normalized and distributed approach. In Proceedings of the 20th ACM Conference on Embedded Networked Sensor Systems (pp. 1083-1088).
74. Tawakuli, A., Kaiser, D., & Engel, T. (2020). Synchronized Preprocessing of Sensor Data. Y 2020 IEEE International Conference on Big Data (Big Data). IEEE. <https://doi.org/10.1109/bigdata50022.2020.9377900> .
75. Rousseeuw, P. J., & Croux, C. (1993). Alternatives to the Median Absolute Deviation. Journal of the American Statistical Association, 88(424), 1273–1283. <https://doi.org/10.1080/01621459.1993.10476408> .
76. Grubbs, F. E. (1969). Procedures for Detecting Outlying Observations in Samples. Technometrics, 11(1), 1–21. <https://doi.org/10.1080/00401706.1969.10490657> .
77. Li, H., Ota, K., & Dong, M. (2018). Learning IoT in Edge: Deep Learning for the Internet of Things with Edge Computing. IEEE Network, 32(1), 96–101. <https://doi.org/10.1109/mnet.2018.1700202> .
78. Olive, D. J. (2004). A resistant estimator of multivariate location and dispersion. Computational Statistics & Data Analysis, 46(1), 93–102. [https://doi.org/10.1016/s0167-9473\(03\)00119-1](https://doi.org/10.1016/s0167-9473(03)00119-1) .
79. Schölkopf, B., Platt, J. C., Shawe-Taylor, J., Smola, A. J., & Williamson, R. C. (2001). Estimating the Support of a High-Dimensional Distribution. Neural Computation, 13(7), 1443–1471. <https://doi.org/10.1162/089976601750264965> .
80. Kotsiantis, Sotiris & Kanellopoulos, Dimitris & Pintelas, P.. (2006). Data Preprocessing for Supervised Learning. International Journal of Computer Science. 1. 111-117.
81. Pigott, T. D. (2001). A review of methods for missing data. Educational research and evaluation, 7(4), 353-383.
82. Rabbath, C. A., & Corriveau, D. (2019). A comparison of piecewise cubic Hermite interpolating polynomials, cubic splines and piecewise linear functions for the approximation of projectile aerodynamics. Defence Technology, 15(5), 741–757. <https://doi.org/10.1016/j.dt.2019.07.016> .

83. Du, J., Hu, M., & Zhang, W. (2020). Missing Data Problem in the Monitoring System: A Review. *IEEE Sensors Journal*, 20(23), 13984–13998. <https://doi.org/10.1109/jsen.2020.3009265>
84. Schölkopf, B., Platt, J. C., Shawe-Taylor, J., Smola, A. J., & Williamson, R. C. (2001). Estimating the Support of a High-Dimensional Distribution. *Neural Computation*, 13(7), 1443–1471. <https://doi.org/10.1162/089976601750264965>
85. Zhu, M., & Shi, H. (2018). A novel support vector machine algorithm for missing data. *Y the 2nd International Conference*. ACM Press. <https://doi.org/10.1145/3194206.3194214>
86. Different types of Time-series Forecasting Models. (2023). Analytics Yogi. <https://vitalflux.com/different-types-of-time-series-forecasting-models/#comments>
87. Hyndman, R. J., & Koehler, A. B. (2006). Another look at measures of forecast accuracy. *International Journal of Forecasting*, 22(4), 679–688. <https://doi.org/10.1016/j.ijforecast.2006.03.001>
88. Goodwin, P., & Lawton, R. (1999). On the asymmetry of the symmetric MAPE. *International Journal of Forecasting*, 15(4), 405–408. [https://doi.org/10.1016/s0169-2070\(99\)00007-2](https://doi.org/10.1016/s0169-2070(99)00007-2)
89. Hansen, L. K., & Salamon, P. (1990). Neural network ensembles. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 12(10), 993–1001. <https://doi.org/10.1109/34.58871>
90. De Gooijer, J. G., & Hyndman, R. J. (2006). 25 years of time series forecasting. *International Journal of Forecasting*, 22(3), 443–473. <https://doi.org/10.1016/j.ijforecast.2006.01.001>
91. LeBaron, B., & Weigend, A. S. (1998). A bootstrap evaluation of the effect of data splitting on financial time series. *IEEE Transactions on Neural Networks*, 9(1), 213–220. <https://doi.org/10.1109/72.655043>
92. Balestrassi, P. P., Popova, E., Paiva, A. P., & Marangon Lima, J. W. (2009). Design of experiments on neural network's training for nonlinear time series forecasting. *Neurocomputing*, 72(4-6),

93. Wang, J., & Wang, J. (2017). Forecasting stochastic neural network based on financial empirical mode decomposition. *Neural Networks*, 90, 8–20.
<https://doi.org/10.1016/j.neunet.2017.03.004>
94. Hamid, S. A., & Habib, A. (2014). Financial forecasting with neural networks. *Academy of Accounting and Financial Studies Journal*, 18(4), 37.
95. Qiu, M., & Song, Y. (2016). Predicting the Direction of Stock Market Index Movement Using an Optimized Artificial Neural Network Model. *PLOS ONE*, 11(5), 1–11. <https://doi.org/10.1371/journal.pone.0155133>
96. Bredahl Kock, A., & Teräsvirta, T. (2015). Forecasting Macroeconomic Variables Using Neural Network Models and Three Automated Model Selection Techniques. *Econometric Reviews*, 35(8-10), 1753–1779.
<https://doi.org/10.1080/07474938.2015.1035163>
97. Gabor, Manuela Rozalia & Dorgo, Lavinia. (2017). Neural Networks Versus Box-Jenkins Method for Turnover Forecasting: a Case Study on the Romanian Organisation. *Transformations in Business and Economics*. 16. 187-211.
98. 97 Marr, B. (2016). The Top 10 AI And Machine Learning Use Cases Everyone Should Know About. *Forbes*.
<https://www.forbes.com/sites/bernardmarr/2016/09/30/what-are-the-top-10-use-casesfor-machine-learning-and-ai/#2c292bf894c9>
99. Ahmed, N. K., Atiya, A. F., Gayar, N. E., & El-Shishiny, H. (2010). An Empirical Comparison of Machine Learning Models for Time Series Forecasting. *Econometric Reviews*, 29(5-6), 594–621.
<https://doi.org/10.1080/07474938.2010.481556>
100. Zhang, G. P., & Qi, M. (2005). Neural network forecasting for seasonal and trend time series. *European Journal of Operational Research*, 160(2), 501–514.
<https://doi.org/10.1016/j.ejor.2003.08.037>
101. Medsker, L., & Jain, L. C. (Eds.). (1999). *Recurrent neural networks: design and applications*. CRC press.
102. Hochreiter, S., & Schmidhuber, J. (1997). Long Short-Term Memory. *Neural Computation*, 9(8), 1735–1780. <https://doi.org/10.1162/neco.1997.9.8.1735>

103. Lippmann, R. (1987). An introduction to computing with neural nets. *IEEE ASSP Magazine*, 4(2), 4–22. <https://doi.org/10.1109/massp.1987.1165576>
104. Zhang, G., Eddy Patuwo, B., & Y. Hu, M. (1998). Forecasting with artificial neural networks: . *International Journal of Forecasting*, 14(1), 35–62. [https://doi.org/10.1016/s0169-2070\(97\)00044-7](https://doi.org/10.1016/s0169-2070(97)00044-7)
105. Møller, M. F. (1993). A scaled conjugate gradient algorithm for fast supervised learning. *Neural Networks*, 6(4), 525–533. [https://doi.org/10.1016/s0893-6080\(05\)80056-5](https://doi.org/10.1016/s0893-6080(05)80056-5)
106. Kourentzes, N., Barrow, D. K., & Crone, S. F. (2014). Neural network ensemble operators for time series forecasting. *Expert Systems with Applications*, 41(9), 4235–4244. <https://doi.org/10.1016/j.eswa.2013.12.011>
107. Bergmeir, C. N., & Benítez Sánchez, J. M. (2012). Neural networks in R using the Stuttgart neural network simulator: RSNNS. *American Statistical Association*. <https://doi.org/10.18637/jss.v046.i07>
108. MacKay, D. J. C. (1992). Bayesian Interpolation. *Neural Computation*, 4(3), 415–447. <https://doi.org/10.1162/neco.1992.4.3.415>
109. Dan Foresee, F., & Hagan, M. T. (б. д.). Gauss-Newton approximation to Bayesian learning. Y *International Conference on Neural Networks (ICNN'97)*. IEEE. <https://doi.org/10.1109/icnn.1997.614194>
110. Nguyen, D., & Widrow, B. (1990). Improving the learning speed of 2-layer neural networks by choosing initial values of the adaptive weights. Y *1990 IJCNN International Joint Conference on Neural Networks*. IEEE. <https://doi.org/10.1109/ijcnn.1990.137819>
111. Rodriguez, P. P., & Gianola, D. (2016). Bayesian Regularization for Feed-Forward Neural Networks. R package p. Package" brnn
112. Specht, D. F. (1991). A general regression neural network. *IEEE Transactions on Neural Networks*, 2(6), 568–576. <https://doi.org/10.1109/72.97934>

113. Chasset, P. O. (2013). GRNN: General regression neural network for the statistical software R. Independent Scientist, Nancy, France, Software. <http://flow.chasset.net/r-grnn/>.
114. Venables, W. N., & Ripley, B. D. (2002). Spatial Statistics. Y Modern Applied Statistics with S (c. 419–434). Springer New York. https://doi.org/10.1007/978-0-387-21706-2_15
115. Breiman, L. (1993). Classification and regression trees. Chapman & Hall.
116. Therneau, T., Atkinson, B., & Ripley, B. (2015). rpart: Recursive partitioning and regression trees. R package version, 4, 1-9. Retrieved from <https://cran.r-project.org/package=rpart>
117. Smola, A. J., & Schölkopf, B. (2001). Learning with Kernels: Support Vector Machines, Regularization, Optimization, and Beyond. The MIT Press. <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.167.5140{&}rep=rep1{&}type=pdf>
118. Meyer, D., Dimitriadou, E., Hornik, K., Weingessel, A., Leisch, F., Chang, C. C., & Lin, C. C. (2017). e1071: Misc functions of the department of statistics, probability theory group (formerly: E1071), TU Wien, version 1.6-8. R package. Retrieved from <https://cran.r-project.org/package=e1071>.
119. Rasmussen, C. E., & Williams, C. K. I. (2006). Gaussian Processes for Machine Learning. The MIT Press. <https://doi.org/10.7551/mitpress/3206.001.0001>
120. Karatzoglou, A., Smola, A., Hornik, K., & Zeileis, A. (2004). kernlab-an S4 package for kernel methods in R. Journal of statistical software, 11, 1-20. <https://doi.org/10.18637/jss.v011.i09>
121. Lindemann, B., Müller, T., Vietz, H., Jazdi, N., & Weyrich, M. (2021). A survey on long short-term memory networks for time series prediction. Procedia CIRP, 99, 650–655. <https://doi.org/10.1016/j.procir.2021.03.088> .
122. GRU Bibi, I., Akhunzada, A., Malik, J., Iqbal, J., Musaddiq, A., & Kim, S. (2020). A dynamic dl-driven architecture to combat sophisticated android malware. IEEE Access, 8, 129600–129612. <https://doi.org/10.1109/access.2020.3009819> .

123. Schuster, M., & Paliwal, K. K. (1997). Bidirectional recurrent neural networks. *IEEE Transactions on Signal Processing*, 45(11), 2673–2681. <https://doi.org/10.1109/78.650093>
124. Waswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A., ... & Polosukhin, I. (2017). Attention is all you need. In NIPS. Retrieved from https://www.aiotlab.org/teaching/dl_app/slides/6_3_attention_n_bert.pdf
125. Devlin, J. (2018). Bert: Pre-training of deep bidirectional transformers for language understanding. Retrieved from <https://arxiv.org/abs/1810.04805>.
126. Anderson, O. D., & Kendall, M. (1976). Time-Series. 2nd edn. *The Statistician*, 25(4), 308. <https://doi.org/10.2307/2988091>
127. Cleveland, R. B., Cleveland, W., McRae, J., & Terpenning, I. (2022). STL: A seasonal-trend decomposition procedure based on loess. 1990. Retrieved from <https://cir.nii.ac.jp/crid/1571417124982951296>
128. Zhou, H., Zhang, S., Peng, J., Zhang, S., Li, J., Xiong, H., & Zhang, W. (2021). Informer: Beyond Efficient Transformer for Long Sequence Time-Series Forecasting. *Proceedings of the AAAI Conference on Artificial Intelligence*, 35(12), 11106–11115. <https://doi.org/10.1609/aaai.v35i12.17325>
129. Sun, K., Xiao, B., Liu, D., & Wang, J. (2019). Deep High-Resolution Representation Learning for Human Pose Estimation. *Y 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. IEEE. <https://doi.org/10.1109/cvpr.2019.00584>
130. Wang, W., Xie, E., Li, X., Fan, D.-P., Song, K., Liang, D., Lu, T., Luo, P., & Shao, L. (2021b). Pyramid Vision Transformer: A Versatile Backbone for Dense Prediction without Convolutions. *Y 2021 IEEE/CVF International Conference on Computer Vision (ICCV)*. IEEE. <https://doi.org/10.1109/iccv48922.2021.00061>
131. Choi, M. J., Chandrasekaran, V., Malioutov, D. M., Johnson, J. K., & Willsky, A. S. (2008). Multiscale stochastic modeling for tractable inference and data assimilation. *Computer Methods in Applied Mechanics and Engineering*, 197(43-44), 3492–3515. <https://doi.org/10.1016/j.cma.2007.12.021>

132. Yu, H., Xin, L., & Dauwels, J. (2019). Variational Wishart Approximation for Graphical Model Selection: Monoscale and Multiscale Models. *IEEE Transactions on Signal Processing*, 67(24), 6468–6482. <https://doi.org/10.1109/tsp.2019.2953651>
133. He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 770-778). https://openaccess.thecvf.com/content_cvpr_2016/html/He_Deep_Residual_Learning_CVPR_2016_paper.html
134. Wu, H., Xu, J., Wang, J., & Long, M. (2021). Autoformer: Decomposition transformers with auto-correlation for long-term series forecasting. *Advances in neural information processing systems*, 34, 22419-22430. <https://proceedings.neurips.cc/paper/2021/hash/bcc0d400288793e8bdcd7c19a8ac0c2b-Abstract.html>
135. Xie, S., Girshick, R., Dollar, P., Tu, Z., & He, K. (2017). Aggregated Residual Transformations for Deep Neural Networks. *Y 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. IEEE. <https://doi.org/10.1109/cvpr.2017.634>
136. Liu, Z., Mao, H., Wu, C.-Y., Feichtenhofer, C., Darrell, T., & Xie, S. (2022). A ConvNet for the 2020s. *Y 2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. IEEE. <https://doi.org/10.1109/cvpr52688.2022.01167>
137. Liu, Z., Lin, Y., Cao, Y., Hu, H., Wei, Y., Zhang, Z., Lin, S., & Guo, B. (2021). Swin Transformer: Hierarchical Vision Transformer using Shifted Windows. *Y 2021 IEEE/CVF International Conference on Computer Vision (ICCV)*. IEEE. <https://doi.org/10.1109/iccv48922.2021.00986>
138. Wang, E., Galjanic, T., & Johnson, R. (2012). Short-term electric load forecasting at Southern California Edison. *Y 2012 IEEE Power & Energy Society General Meeting. New Energy Horizons - Opportunities and Challenges*. IEEE. <https://doi.org/10.1109/pesgm.2012.6345494>

139. Goswami, K., & Kandali, A. B. (2020). Electricity Demand Prediction using Data Driven Forecasting Scheme: ARIMA and SARIMA for Real-Time Load Data of Assam. Y 2020 International Conference on Computational Performance Evaluation (ComPE). IEEE. <https://doi.org/10.1109/compe49325.2020.9200031>
140. Putra, J. A., Bukhori, S., & Basbeth, F. (2019). Sugar Production Forecasting System in PTPN XI Semboro Jember using Autoregressive Integrated Moving Average (ARIMA) Method. Proceeding of the Electrical Engineering Computer Science and Informatics, 6(1). <https://doi.org/10.11591/eecs.v6.1988>
141. Shao, X., Ma, D., Liu, Y., & Yin, Q. (2017). Short-term forecast of stock price of multi-branch LSTM based on K-means. Y 2017 4th International Conference on Systems and Informatics (ICSAI). IEEE. <https://doi.org/10.1109/icsai.2017.8248530>
142. Jian Zheng, Cencen Xu, Ziang Zhang & Xiaohua Li. (2017). Electric load forecasting in smart grids using Long-Short-Term-Memory based Recurrent Neural Network. Y 2017 51st Annual Conference on Information Sciences and Systems (CISS). IEEE. <https://doi.org/10.1109/ciss.2017.7926112>
143. Marino, D. L., Amarasinghe, K., & Manic, M. (2016). Building energy load forecasting using Deep Neural Networks. Y IECON 2016 - 42nd Annual Conference of the IEEE Industrial Electronics Society. IEEE. <https://doi.org/10.1109/iecon.2016.7793413>
144. Wu, D. C. W., Ji, L., He, K., & Tso, K. F. G. (2020). Forecasting Tourist Daily Arrivals With A Hybrid Sarima–Lstm Approach. Journal of Hospitality & Tourism Research, 45(1), 52–67. <https://doi.org/10.1177/1096348020934046>
145. Shelatkar, T., Tondale, S., Yadav, S., & Ahir, S. (2020). Web Traffic Time Series Forecasting using ARIMA and LSTM RNN. ITM Web of Conferences, 32, 03017. <https://doi.org/10.1051/itmconf/20203203017>
146. Wang, D., Meng, Y., Chen, S., Xie, C., & Liu, Z. (2021). A Hybrid Model for Vessel Traffic Flow Prediction Based on Wavelet and Prophet. Journal of Marine Science and Engineering, 9(11), 1231. <https://doi.org/10.3390/jmse9111231>

147. Khandelwal, I., Adhikari, R., & Verma, G. (2015). Time Series Forecasting Using Hybrid ARIMA and ANN Models Based on DWT Decomposition. *Procedia Computer Science*, 48, 173–179. <https://doi.org/10.1016/j.procs.2015.04.167>
148. Zhang, W., Lin, Z., & Liu, X. (2022). Short-term offshore wind power forecasting - A hybrid model based on Discrete Wavelet Transform (DWT), Seasonal Autoregressive Integrated Moving Average (SARIMA), and deep-learning-based Long Short-Term Memory (LSTM). *Renewable Energy*, 185, 611–628. <https://doi.org/10.1016/j.renene.2021.12.100>
149. Zeng, Z., & Khushi, M. (2020). Wavelet Denoising and Attention-based RNN- ARIMA Model to Predict Forex Price. Y 2020 International Joint Conference on Neural Networks (IJCNN). IEEE. <https://doi.org/10.1109/ijcnn48605.2020.9206832>
150. Qiu, J., Du, Q., Wang, W., Yin, K., & Chen, L. (2019). Short-Term Performance Metrics Forecasting for Virtual Machine to Support Anomaly Detection Using Hybrid ARIMA-WNN Model. Y 2019 IEEE 43rd Annual Computer Software and Applications Conference (COMPSAC). IEEE. <https://doi.org/10.1109/compsac.2019.10228>
151. Yu, S., Dong, H., Chen, Y., He, Z., & Shi, X. (2019). Clothing Sales Forecast Based on ARIMA-BP Neural Network Combination Model. Y 2019 IEEE International Conference on Power, Intelligent Computing and Systems (ICPICS). IEEE. <https://doi.org/10.1109/icpics47731.2019.8942427>
152. Hadwan, M., M. Al-Maqaleh, B., N. Al-Badani, F., Ullah Khan, R., & A. Al-Hagery, M. (2022). A Hybrid Neural Network and Box-Jenkins Models for Time Series Forecasting. *Computers, Materials & Continua*, 70(3), 4829–4845. <https://doi.org/10.32604/cmc.2022.017824>
153. Hua, S. (2022). Back-Propagation Neural Network and ARIMA Algorithm for GDP Trend Analysis. *Wireless Communications and Mobile Computing*, 2022, 1–9. <https://doi.org/10.1155/2022/1967607>
154. Wang, Y.-w., Shen, Z.-z., & Jiang, Y. (2019). Comparison of autoregressive integrated moving average model and generalised regression neural network model

- for prediction of haemorrhagic fever with renal syndrome in China: a time-series study. *BMJ Open*, 9(6), Стаття e025773. <https://doi.org/10.1136/bmjopen-2018-025773>
155. Li, Z., Wang, Z., Song, H., Liu, Q., He, B., Shi, P., Ji, Y., Xu, D., & Wang, J. (2019). Application of a hybrid model in predicting the incidence of tuberculosis in a Chinese population. *Infection and Drug Resistance*, Volume 12, 1011–1020. <https://doi.org/10.2147/idr.s190418>
 156. Cheng, Y., Zhu, Q., Peng, Y., Huang, X.-F., & He, L.-Y. (2021). Multiple strategies for a novel hybrid forecasting algorithm of ozone based on data-driven models. *Journal of Cleaner Production*, 326, 129451. <https://doi.org/10.1016/j.jclepro.2021.129451>
 157. Wu, X., Zhou, J., Yu, H., Liu, D., Xie, K., Chen, Y., Hu, J., Sun, H., & Xing, F. (2021). The Development of a Hybrid Wavelet-ARIMA-LSTM Model for Precipitation Amounts and Drought Analysis. *Atmosphere*, 12(1), 74. <https://doi.org/10.3390/atmos12010074>
 158. Zhang, M., Wang, Y., Wang, X., & Zhou, W. (2021). Groundwater Depth Forecasting Using a Coupled Model. *Discrete Dynamics in Nature and Society*, 2021, 1–11. <https://doi.org/10.1155/2021/6614195>
 159. Eua-Arporn, B., Huang, S.-L., & Kuruoglu, E. E. (2021). Enhancing Neural Network Based Hybrid Learning with Empirical Wavelet Transform for Time Series Forecasting. Y 2021 IEEE 33rd International Conference on Tools with Artificial Intelligence (ICTAI). IEEE. <https://doi.org/10.1109/ictai52525.2021.00063>.
 160. Peirano, R., Kristjanpoller, W., & Minutolo, M. C. (2021). Forecasting inflation in Latin American countries using a SARIMA–LSTM combination. *Soft Computing*, 25(16), 10851–10862. <https://doi.org/10.1007/s00500-021-06016-5>.
 161. Yilmaz F. M., Arabaci O. Yilmaz, F. M., & Arabaci, O. (2020). Should Deep Learning Models be in High Demand, or Should They Simply be a Very Hot Topic? A Comprehensive Study for Exchange Rate Forecasting. *Computational Economics*. <https://doi.org/10.1007/s10614-020-10047-9>.

162. Li, Q., Zhao, Y., & Yu, F. (2020). A Novel Multichannel Long Short-Term Memory Method With Time Series for Soil Temperature Modeling. *IEEE Access*, 8, 182026–182043. <https://doi.org/10.1109/access.2020.3028995>
163. Yu, L., Wu, C., & Xiong, N. N. (2022). An Intelligent Data Analysis System Combining ARIMA and LSTM for Persistent Organic Pollutants Concentration Prediction. *Electronics*, 11(4), 652. <https://doi.org/10.3390/electronics11040652>
164. Sun, Q., Wan, J., & Liu, S. (2020). Estimation of Sea Level Variability in the China Sea and Its Vicinity Using the SARIMA and LSTM Models. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 13, 3317–3326. <https://doi.org/10.1109/jstars.2020.2997817>
165. Wang, Q., & Jiang, F. (2019). Integrating linear and nonlinear forecasting techniques based on grey theory and artificial intelligence to forecast shale gas monthly production in Pennsylvania and Texas of the United States. *Energy*, 178, 781–803. <https://doi.org/10.1016/j.energy.2019.04.115>
166. Belmahdi, B., Louzazni, M., & Bouardi, A. E. (2020). A hybrid ARIMA–ANN method to forecast daily global solar radiation in three different cities in Morocco. *The European Physical Journal Plus*, 135(11). <https://doi.org/10.1140/epjp/s13360-020-00920-9>
167. Azad, A. S., Sokkalingam, R., Daud, H., Adhikary, S. K., Khurshid, H., Mazlan, S. N. A., & Rabbani, M. B. A. (2022). Water level prediction through hybrid SARIMA and ANN models based on time series analysis: Red hills reservoir case study. *Sustainability*, 14(3), 1843. <https://doi.org/10.3390/su14031843>
168. Yu, K. W., Hsu, C. H., & Yang, S. M. (2019). A model integrating ARIMA and ANN with seasonal and periodic characteristics for forecasting electricity load dynamics in a state. *Y 2019 IEEE 6th international conference on energy smart systems (ESS)*. IEEE. <https://doi.org/10.1109/ess.2019.8764179>
169. Temür, A. S., Akgün, M., & Temür, G. (2019). PREDICTING HOUSING SALES IN TURKEY USING ARIMA, LSTM AND HYBRID MODELS. *Journal*

- of Business Economics and Management, 20(5), 920–938.
<https://doi.org/10.3846/jbem.2019.10190>
170. Soy Temür, A., & Yıldız, Ş. (2021). Comparison of Forecasting Performance of ARIMA LSTM and HYBRID Models for The Sales Volume Budget of a Manufacturing Enterprise. *Istanbul Business Research*, 50(1), 15–46.
<https://doi.org/10.26650/ibr.2021.51.0117>
 171. Nazemi, K., & Burkhardt, D. (2019). Visual Analytics for Analyzing Technological Trends from Text. Y 2019 23rd International Conference Information Visualisation (IV). IEEE. <https://doi.org/10.1109/iv.2019.00041>
 172. Nazemi, K., Burkhardt, D., & Kock, A. (2021). Visual analytics for technology and innovation management. *Multimedia Tools and Applications*.
<https://doi.org/10.1007/s11042-021-10972-3>
 173. Nazemi, K., Feiter, T., Sina, L. B., Burkhardt, D., & Kock, A. (2022). Visual Analytics for Strategic Decision Making in Technology Management. Y *Studies in Computational Intelligence* (c. 31–61). Springer International Publishing.
https://doi.org/10.1007/978-3-030-93119-3_2
 174. Sina, L. B., & Nazemi, K. (2022). Visual Analytics for Systematic Reviews According to PRISMA. Y 2022 26th International Conference Information Visualisation (IV). IEEE. <https://doi.org/10.1109/iv56949.2022.00059>
 175. Sina, L. B., Burkhardt, D., & Nazemi, K. (2020). Visual Dashboards in Trend Analytics to Observe Competitors and Leading Domain Experts. In *CERC* (pp. 222–235).
 176. Kovalerchuk, B., Andonie, R., Datia, N., Nazemi, K., & Banissi, E. (2022). Visual Knowledge Discovery with Artificial Intelligence: Challenges and Future Directions. Y *Studies in Computational Intelligence* (c. 1–27). Springer International Publishing. https://doi.org/10.1007/978-3-030-93119-3_1
 177. Kohlhammer, J., May, T., & Hoffmann, M. (2009). Visual Analytics for the Strategic Decision Making Process. Y *GeoSpatial Visual Analytics* (c. 299–310). Springer Netherlands. https://doi.org/10.1007/978-90-481-2899-0_23

178. Дячук, Д. Д., Мороз, Г. З., Гідзинська, І. М., Кравченко, А. М., & Дзізінська, О. О. (2024). Профілактика серцево-судинних захворювань: Теоретичні засади та практичне впровадження. Державна наукова установа «Центр інноваційних технологій охорони здоров'я» Державного управління справами. <https://doi.org/10.31612/9786178463137>
179. Гіпертонія 2 ступеня: Діагностика, профілактика та лікування. (б. д.). Медичний центр "Альтернатива". <https://mc-alternativa.com.ua/gipertoniya-2-stupenya-diagnostyka-profilaktyka-ta-likuvannya/>
180. Soh, D. C. K., Ng, E. Y. K., Jahmunah, V., Oh, S. L., San, T. R., & Acharya, U. R. (2020). A computational intelligence tool for the detection of hypertension using empirical mode decomposition. *Computers in Biology and Medicine*, 118, 103630. <https://doi.org/10.1016/j.compbiomed.2020.103630>
181. LaFreniere, D., Zulkernine, F., Barber, D., & Martin, K. (2016). Using machine learning to predict hypertension from a clinical dataset. *У 2016 IEEE Symposium Series on Computational Intelligence (SSCI)*. IEEE. <https://doi.org/10.1109/ssci.2016.7849886>
182. Tang, Z.-H., Liu, J., Zeng, F., Li, Z., Yu, X., & Zhou, L. (2013). Comparison of Prediction Model for Cardiovascular Autonomic Dysfunction Using Artificial Neural Network and Logistic Regression Analysis. *PLoS ONE*, 8(8), e70571. <https://doi.org/10.1371/journal.pone.0070571>
183. Ture, M., Kurt, I., Turhankurum, A., & Ozdamar, K. (2005). Comparing classification techniques for predicting essential hypertension. *Expert Systems With Applications*, 29(3), 583–588. <https://doi.org/10.1016/j.eswa.2005.04.014>
184. Lynn, K.-S., Li, L.-L., Lin, Y.-J., Wang, C.-H., Sheng, S.-H., Lin, J.-H., Liao, W., Hsu, W.-L., & Pan, W.-H. (2009). A neural network model for constructing endophenotypes of common complex diseases: an application to male young-onset hypertension microarray data. *Bioinformatics*, 25(8), 981–988. <https://doi.org/10.1093/bioinformatics/btp106>

185. Zhao, Y., Gao, J., & Yang, X.. A survey of neural network ensembles. Y 2005 International Conference on Neural Networks and Brain. IEEE. <https://doi.org/10.1109/icnnb.2005.1614650>
186. Rokach, L. (2009). Ensemble-based classifiers. Artificial Intelligence Review, 33(1-2), 1–39. <https://doi.org/10.1007/s10462-009-9124-7>
187. Gopika, D., & Azhagusundari, B. (2014). An analysis on ensemble methods in classification tasks. International Journal of Advanced Research in Computer and Communication Engineering 3 (2014) 7423–7427.
188. Yang, P., Hwa Yang, Y., B. Zhou, B., & Y. Zomaya, A. (2010). A Review of Ensemble Methods in Bioinformatics. Current Bioinformatics, 5(4), 296–308. <https://doi.org/10.2174/157489310794072508>
189. Mendes-Moreira, J., Soares, C., Jorge, A. M., & Sousa, J. F. D. (2012). Ensemble approaches for regression. ACM Computing Surveys, 45(1), 1–40. <https://doi.org/10.1145/2379776.2379786>
190. Ren, Y., Suganthan, P. N., & Srikanth, N. (2015). Ensemble methods for wind and solar power forecasting—A state-of-the-art review. Renewable and Sustainable Energy Reviews, 50, 82–91. <https://doi.org/10.1016/j.rser.2015.04.081>
191. Vega-Pons, S., & Ruiz-Shulcloper, J. (2011). A survey of clustering ensemble algorithms. International Journal of Pattern Recognition and Artificial Intelligence, 25(03), 337–372. <https://doi.org/10.1142/s0218001411008683>
192. Dietterich, T. G. (2000). Ensemble Methods in Machine Learning. Y Multiple Classifier Systems (c. 1–15). Springer Berlin Heidelberg. https://doi.org/10.1007/3-540-45014-9_1
193. Breiman, L. (1996). Bagging predictors. Machine Learning, 24(2), 123–140. <https://doi.org/10.1007/bf00058655>
194. Freund, Y., & Schapire, R. E. (1996, July). Experiments with a new boosting algorithm. In icml (Vol. 96, pp. 148-156). Retrieved from <https://citeseerx.ist.psu.edu/document?repid=rep1&type=pdf&doi=d186abec952c4348870a73640bf849af9727f5a4>

195. Tin Kam Ho. (1998). The random subspace method for constructing decision forests. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 20(8), 832–844. <https://doi.org/10.1109/34.709601>
196. Breiman, L. (2001) Random Forests. *Machine Learning* 45, 5–32. <https://doi.org/10.1023/A:1010933404324>.
197. Breiman, L. (2000) Randomizing Outputs to Increase Prediction Accuracy. *Machine Learning* 40, 229–242. <https://doi.org/10.1023/A:1007682208299>.
198. Breiman, L. (1996). Bagging predictors. *Machine Learning*, 24(2), 123–140. <https://doi.org/10.1007/bf00058655>
199. Bühlmann, P., & Yu, B. (2002). Analyzing bagging. *The Annals of Statistics*, 30(4), 927–961. <https://doi.org/10.1214/aos/1031689014>
200. Hido, S., Kashima, H., & Takahashi, Y. (2009). Roughly balanced bagging for imbalanced data. *Statistical Analysis and Data Mining*, 2, 412–426. <https://doi.org/10.1002/sam.10061>
201. Błaszczyński, J., & Stefanowski, J. (2015). Neighbourhood sampling in bagging for imbalanced data. *Neurocomputing*, 150, 529–542. <https://doi.org/10.1016/j.neucom.2014.07.064>
202. Friedman, J. H. (2001). Greedy Function Approximation: A Gradient Boosting Machine. *The Annals of Statistics*, 29(5), 1189–1232. Retrieved from <http://www.jstor.org/stable/2699986>
203. Cortes, C., Mohri, M. & Syed, U.. (2014). Deep Boosting. *Proceedings of the 31st International Conference on Machine Learning*, in *Proceedings of Machine Learning Research* 32(2):1179-1187. Retrieved from <https://proceedings.mlr.press/v32/cortesb14.html>.
204. Kuznetsov, V., Mohri, M., & Syed, U. (2014). Multi-class deep boosting. *Advances in Neural Information Processing Systems*, 27. Retrieved from https://proceedings.neurips.cc/paper_files/paper/2014/hash/7bb060764a818184ebb1cc0d43d382aa-Abstract.html.
205. González, S., García, S., Del Ser, J., Rokach, L., & Herrera, F. (2020). A practical tutorial on bagging and boosting based ensembles for machine learning:

- Algorithms, software tools, performance study, practical perspectives and opportunities. *Information Fusion*, 64, 205–237.
<https://doi.org/10.1016/j.inffus.2020.07.007>
206. Wolpert, D. H. (1992). Stacked generalization. *Neural networks*, 5(2), 241–259. [https://doi.org/10.1016/S0893-6080\(05\)80023-1](https://doi.org/10.1016/S0893-6080(05)80023-1)
207. Leblanc, M., & Tibshirani, R. (1996). Combining Estimates in Regression and Classification. *Journal of the American Statistical Association*, 91(436), 1641–1650. <https://doi.org/10.1080/01621459.1996.10476733>
208. Deng, L., & Yu, D. (2011). Deep convex net: a scalable architecture for speech pattern classification. *Interspeech 2011. ISCA*.
<https://doi.org/10.21437/interspeech.2011-607>
209. Palangi, H., Deng, L., & Ward, R. K. (2014). Recurrent Deep-Stacking Networks for sequence classification. *У 2014 IEEE China Summit & International Conference on Signal and Information Processing (ChinaSIP)*. IEEE.
<https://doi.org/10.1109/chinasip.2014.6889295>
210. Чумаченко, О. І. (2019). Структурно-параметричний синтез гібридних нейронних мереж [Дис. д-ра техн. наук, Національний технічний університет України «Київський політехнічний інститут імені Ігоря Сікорського»].
https://ela.kpi.ua/bitstream/123456789/29639/1/Chumachenko_diss.pdf

ДОДАТОК А. АКТ ВПРОВАДЖЕННЯ В ДУ «НАЦІОНАЛЬНИЙ НАУКОВИЙ ЦЕНТР ІМЕНІ АКАДЕМІКА М.Д. СТРАЖЕСКА»

ДУ «Національний науковий центр
ім. акад. М.Д. Стражеска НАМН України»
Юридична адреса:
Україна, м. Київ, 03680,
Вул. Святослава Хороброго, буд.5
Ідентифікаційний код
згідно з ЄДРПОУ: 44854985
Тел: (044) 275 66 22
E-mail: stragh.cardio@gmail.com

АКТ

впровадження дисертаційних результатів Коломойця С.О. на тему
«Методи інтелектуального прогнозування артеріального тиску та
класифікації артеріальної гіпертензії»

18.12.2024

м. Київ

Ми, комісія у складі: Талаєва Т.В. – д.м.н., учений секретар ДУ «Національний науковий центр ім. акад. М.Д. Стражеска», Міщенко Л.А. – д.м.н., завідувач відділу артеріальної гіпертензії та коморбідної патології, Матова О.О. – старший науковий співробітник відділу артеріальної гіпертензії та коморбідної патології, розглянувши дисертаційну роботу Коломойця С.О. прийшли до висновку що положення дисертації, а саме: алгоритми прогнозування артеріального тиску, алгоритми визначення ступеня захворювання пацієнтів на артеріальну гіпертензію було впроваджено в ДУ «Національний науковий центр ім. акад. М.Д. Стражеска» при виконанні досліджень з приводу захворювань пацієнтів на артеріальну гіпертензію, що дозволило знизити кількість ускладнень захворювання та забезпечити більш комфортні умови їх життя під час хвороби.

Члени комісії:

Тетяна ТАЛАЄВА

Лариса МІЩЕНКО

Олена МАТОВА