

**О. І. Стасюк<sup>1</sup>, Л. Л. Гончарова<sup>2</sup>**

<sup>1,2</sup>Державний університет інфраструктури та технологій, Україна  
9, вул. Кирилівська, м. Київ, 04071

<sup>1</sup>ostasuk177@gmail.com

<sup>2</sup>ktarae188@gmail.com

<sup>1</sup><https://orcid.org/0000-0002-2889-2288>

<sup>2</sup><https://orcid.org/0000-0003-0116-0682>

## **МАТЕМАТИЧНІ ІННОВАЦІЙНО – ПІЗНАВАЛЬНІ МОДЕЛІ ШТУЧНОГО ІНТЕЛЕКТУ НА ОСНОВІ ТЕОРІЇ ДИФЕРЕНЦІЙНИХ ПЕРЕТВОРЕНЬ**

**Анотація.** Проведено аналіз проблеми масового використання штучного інтелекту. Обґрунтовано напрямки наукових досліджень, пов'язаний зі створенням диференційних моделей штучного інтелекту. Для аналізу і прогнозу нових значень залежних і незалежних змінних наведено спосіб представлення їх попередніх значень у вигляді часового ряду. Запропоновано ряд диференційних математичних моделей для проведення регресивного аналізу. Показано представлення інформації в матрично-векторній формі між шарами нейронної мережі. Розроблено методи прогнозування значень ваг і кореляційного аналізу для стабільності моделі штучного інтелекту.

**Ключові слова:** аналіз, прогноз, математичні моделі, диференційні перетворення, штучний інтелект, регресивний аналіз, нейромережі.

**O. Stasiuk<sup>1</sup>, L. Goncharova<sup>2</sup>**

<sup>1,2</sup> State University of Infrastructure and Technologies, Ukraine  
9, st. Kyrylivska, Kyiv, 04071

<sup>1</sup>ostasuk177@gmail.com

<sup>2</sup>ktarae188@gmail.com

<sup>1</sup><https://orcid.org/0000-0002-2889-2288>

<sup>2</sup><https://orcid.org/0000-0003-0116-0682>

## **INNOVATIVE MATHEMATICAL - COGNITIVE MODELS OF ARTIFICIAL INTELLIGENCE BASED ON THEORY OF DIFFERENTIAL TRANSFORMATIONS**

**Abstract.** An analysis of the problem of mass development of piece intelligence has been carried out. Direct scientific research related to the creation of differential models of piece intelligence has been carried out. For the analysis and forecast of new values of stale and non-stable changeables, a method has been introduced to present their leading values in a time series. A number of differential mathematical models have been developed for conducting regression analysis. The representation of information in matrix-vector form between the balls of the neural network is shown. Methods for predicting the value of values and correlation analysis for the stability of the model of piece intelligence have been developed.

**Keywords:** analysis, forecast, mathematical models, differential transformations, piece intelligence, regression analysis, neuromergment.

### **Вступ**

Результати досліджень еволюції масового використання штучного інтелекту (ШІ), як однієї з ключових революційних технологій сучасності, демонструють стрімкий розвиток сучасного світу та все більш масштабні процеси його модернізації. Цей аспект є ключовим, оскільки методи ШІ орієнтовані на корінне перетворення концепцій та форматів

функціонування соціально-економічних систем усіх рівнів, забезпечення стрімкого переходу до епохи знань, творчості, а також стимулювання суттєвого прискорення темпів науково-технічного та соціально-економічного розвитку, як основи конкурентоспроможності, формування високого рівня національної безпеки та гідного місця держави у світовому цивілізаційному просторі [1-4]. Сучасні

інноваційні технології ШІ диктують не тільки нові принципи функціонування всіх галузей нашого життя, починаючи від роботи банківської системи до охорони здоров'я, а також стимулюють створення нового інноваційно-інвестиційного продукту, з новим функціоналом та споживчими властивостями для синтезу «проривних» інтелектуальних технологій у конкретних сферах та індустріях, зокрема у сфері науки та освіти [2, 5]. Створення мережеских платформ інтеграції та методології взаємодії користувачів інтелектуальних технологій є основою глибокого перетворення стратегічних та корпоративних моделей і структур соціально-економічної системи суспільства, їх стратегій розвитку, всеосяжної сервісизації економіки, маркетингового підходу, корпоративної культури та інновацій у цифровому бізнесовому просторі. Революція в галузі організації штучного інтелекту вимагає переосмислення та реформування всіх сфер нашого життя, обіцяючи з одного боку неймовірні інновації, а з іншого - зіштовхує з новими викликами. Застосування цих перетворень, у контексті ШІ, дозволяє розробляти нові підходи до навчання та оптимізації інтелектуальних алгоритмів, а також сприяє, що дуже важливо, кращому розумінню закономірностей та взаємозв'язків у великих обсягах даних [3-7]. Піднімається ряд проблем дослідження стану та поведінки складних енергетичних та біологічних систем управління. З'явилась необхідність в розробці і застосуванні нових принципів їх організації для спроможності накопичування нових знань про природу режимів функціонування об'єктів. Застосування перспективних моделей і методів штучного інтелекту у всіх сферах народного господарства змушує переглянути існуючі математичні моделі, методи і алгоритми, включаючи також логічні та математичні абстракції їх функціонування. Стало очевидним, що головним принципом роботи моделей штучного інтелекту є принцип прийняття рішень, тобто вони використовуються для прогнозування чи ухвалення рішень, а

інтелектуальні алгоритми — це логіка, згідно з якою працює ця модель [2, 8].

Оскільки на сучасному етапі весь світ переживає стрімкий розвиток у сфері штучного інтелекту, то, з ряду причин, для розуміння та подальшого прогресу цієї революційної технології, стала актуальною проблемою необхідність створення нового класу інноваційно-пізнавальних математичних моделей штучного інтелекту підвищеної розмірності і інтелектуальної складності, орієнтованих на визначення вичерпної інформативності первинних даних, імітації творчої діяльності та формування нових знань. В зв'язку з цим, використовуючи основні теорії диференційних перетворень, детально розглянемо методологію синтезу математичних інноваційно – пізнавальних моделей та обговоримо їх переваги і особливості застосування в різних сферах [5-10].

### **Аналіз останніх досліджень та публікацій**

Аналіз публікацій вітчизняних та зарубіжних учених показав, що на сьогоднішній день активно обговорюються і розвиваються ключові аспекти і проблеми розвитку ШІ та його впливів на різні галузі суспільства. Сучасний етап розвитку та використання ШІ характеризується стрімким зростанням обсягу даних, які необхідно обробляти та аналізувати в реальному часі для прийняття рішень [1, 3]. Останні дослідження у цій сфері показали, що наукові розробки стрімко розвиваються і необхідність в створенні нових математичних моделей з'являється регулярно. Моделі ШІ дозволяють ефективно вирішувати завдання класифікації, прогнозування, оптимізації, управління економічними процесами, розробки соціальних програм та інші, що має важливе значення для багатьох областей, включаючи медицину, фінанси, промисловість тощо. Виклики, з якими стикається суспільство у зв'язку з розвитком штучного інтелекту, включають такі напрями як рішення складних соціальних проблем, створення автономних систем, таких як безпілотні автомобілі, дрони та роботи, що можуть

виконувати різноманітні завдання без прямого контролю людини, а також прогнозування поведінки ШІ, розширення здібностей навчання, покращення алгоритмів та методів. Ці напрями відображають поточні тенденції у дослідженнях ШІ та вказують на галузі, в яких створюються сучасні математичні моделі. Створення нових моделей та новітньої методології машинного навчання сприяють винайденню нових застосувань ШІ в різних галузях, вдосконаленню інтелектуальних алгоритмів, зменшуючи час їхньої роботи та ресурси, які вони використовують, або покращуючи їхню точність, а також відкривають можливість суттєво збільшувати позитивний вплив на суспільство. Крім того, розвиток математичних моделей ШІ стимулює прогрес у теорії та методах машинного навчання, що у свою чергу призводить до створення нових, ефективніших методів, алгоритмів та підходів [2]. Результати аналізу новітніх досягнень в даній сфері дозволили зробити висновок, що подальший прогрес в цьому напрямку неможливий без створення нового класу інноваційно – пізнавальних математичних моделей в області сучасного ШІ, які відображали б виклики сучасності та вимоги до більшої ефективності їх використання, включаючи точність функціонування і етику використання. Необхідність створення нового класу математичних моделей обумовлена також безліччю факторів, таких як: великі обсяги даних, складність сучасних завдань, потреба в розв'язанні складних соціальних проблем, оскільки існуючі моделі можуть не враховувати всі аспекти складності даних чи контексту завдання, а сучасні завдання в системах ШІ все частіше вимагають інтеграції знань з різних дисциплін. Нові моделі відкривають можливість покращити проблеми інтерпретації та прозорості, тому що існуючі моделі ШІ, особливо глибокі нейронні мережі, часто вважаються "чорними скриньками". Це ускладнює пояснення отриманих рішень, що є суттєвим у критично важливих областях, таких як енергетика, медицина або

юридичні системи. Інтерпретованість моделей відкриває можливість зрозуміти, чому і як інтелектуальні алгоритми приймають певні рішення, що критично важливо для їхнього застосування у відповідальних областях, а також при використанні у міждисциплінарних контекстах [2 - 8]. Розробка нового класу моделей ШІ сприяє також більш глибокому розумінню процесів формування штучного інтелекту, його адаптованості до різних завдань та забезпечує більш безпечне та етичне використання технологій. Інтелектуальні математичні моделі дозволяють більш точно та ефективно вирішувати завдання, пов'язані з обробкою та аналізом даних, прогнозуванням, оптимізацією тощо. Використання математичних методів та алгоритмів дозволяє покращити якість прийнятих рішень та підвищити продуктивність систем. Важливим фактором являється також забезпечення стійкості до помилок та атак на моделі ШІ, включаючи атаки на основні дані або їх класифікації. Більш стійкі математичні моделі можуть підвищити безпеку ШІ та зменшити ризик виникнення критичних помилок.

Таким чином, створення нового класу математичних моделей сприяє більш глибокому розумінню сучасного штучного інтелекту, покращенню ефективності, надійності та безпеки систем, адаптованості до різних завдань, можливості більш безпечного та етичного використання інтелектуальних технологій, а також суттєво посилює їх позитивний вплив на економіку, технології і суспільство [2].

### **Постановка проблеми**

Створення сучасних і перспективних математичних моделей штучного інтелекту є багатогранною проблемою, яка потребує міждисциплінарного підходу. Сучасні моделі ШІ включають обчислювальні архітектури, інтелектуальні алгоритми та програми, які здатні обробляти та інтерпретувати сенсорні дані, такі як зображення, звук, текст тощо та імітувати процеси сприйняття інформації аналогічно людському сприйняттю, і

використовуватися для вирішення проблемних питань практично всіх галузей економіки та суспільства [2]. Прогрес у цій сфері відкриває ряд нових можливостей для вирішення складних завдань сучасності, проте порушує ряд питань, таких як інтерпретованості, прозорості та етики використання ШІ. В якості прикладу перспективних моделей ШІ можна вказати на згорткові нейронні мережі (CNN), орієнтовані на розпізнавання зображень та об'єктів, а також різновидності рекурентних нейронних мереж (RNN), що застосовуються для обробки послідовних даних, включаючи тексти та часові ряди. Стрімке збільшення обсягів даних та складності завдань сучасності створюють ряд проблем організації ефективності та масштабованості перспективних моделей ШІ. Значна складність сучасних моделей ШІ, таких як глибокі нейронні мережі, робить їх важко інтерпретованими - "чорними скриньками". Це означає, що пояснити, чому модель прийняла певне рішення може бути викликом, особливо в областях, де прозорість і розуміння рішень, що приймаються ШІ, критично важливі. Інтерпретованість та прозорість таких моделей залишаються важливими проблемами, оскільки вони необхідні для розуміння та довіри до рішень.

Однією із ключових проблем сучасних моделей ШІ також є спроможність до узагальнення - ефективного опрацювання нових даних, не представлених раніше у навчальних наборах. Розуміння цієї багатогранної проблеми вимагає розробки принципово нових математичних моделей ШІ, які можуть краще відповідати сучасним вимогам, включаючи процедури створення обчислювальних архітектур, методів та алгоритмів, здатних ефективно працювати на великих інформаційних даних та використовувати обчислювальні ресурси оптимально. В цьому аспекті, на сучасному етапі розвитку інтелектуальних технологій, проблема створення принципово нових математичних моделей, орієнтованих для систем штучного інтелекту, є вкрай важливою і актуальною [2-7]. Створення сучасних математичних моделей штучного

інтелекту відкриває можливість покращення розуміння його роботи, вдосконалення алгоритмів, визначення можливостей ШІ, включаючи обмеження і потенційні ризики, сприяння винайденню нових застосувань ШІ в різних галузях, а також можливість використання для навчання ШІ і надання зворотного зв'язку. Різноманіття підходів до моделювання інтелектуальних процедур, з метою створення більш потужних та універсальних моделей ШІ для вирішення конкретних завдань, відображається в використанні комбінації різних математичних моделей та методів. Найважливіші математичні моделі штучного інтелекту відіграють ключову роль в розробці алгоритмів і систем, що дозволяють комп'ютерному середовищу навчатися і приймати рішення з урахуванням даних. Деякі з цих математичних моделей включають лінійні моделі, які широко застосовуються у завданнях регресії та класифікації, ймовірні моделі, нейронні мережі, дерева прийняття рішень, моделі кластеризації, еволюційні алгоритми та ін.

#### **Мета та завдання дослідження**

На основі теорії диференційних перетворень створити наукові засади синтезу диференційних інноваційно - пізнавальних математичних моделей штучного інтелекту підвищеної інтелектуальної складності і розмірності, орієнтованих для визначення вичерпної інформативності впорядкованих вимірів режимів функціонування складних енергетичних та біологічних об'єктів і забезпечити можливість реалізації процедур імітації творчої діяльності, формування нових знань, прогнозу, надійності функціонування, синтезу керуючих впливів при реалізації стратегічних функцій і цілей та формування інтелектуальних технологій.

#### **Основний матеріал дослідження**

Організація ефективних і потужних систем сучасного штучного інтелекту та необхідність розуміння процесів взаємодії відповідної множини різних компонентів

інтелектуальної системи, які комунікують і підтримують один-одного, яка неможлива без структурованого підходу, виділяючи апаратну основу, теоретичні та практичні аспекти функціонування, а також кінцеві сфери застосування [1-7]. Моделі ШІ можуть бути розглянуті з різних перспектив, включаючи функціональність, методологію, рівень інтелекту та сферу застосування. Представляється доречною архітектура систем штучного інтелекту, що включає кілька рівнів, кожен з яких виконує свої специфічні функції і забезпечує роботу системи в цілому. Перший апаратно-програмний рівень - це платформа, що складається з фізичних комп'ютерних компонентів, які забезпечують обчислювальну потужність, необхідну для роботи систем штучного інтелекту в реальному часі і являється апаратною основою, яка формується із найсучасніших багатоядерних чипів, виготовлених за 3-5нм технологією. Другий рівень – теоретичні аспекти організації нових математичних моделей штучного інтелекту та інтелектуальні методи обробки, третій - відповідно інтелектуальні алгоритми і програми системного та прикладного характеру. Четвертий рівень - застосування в різних сферах людської діяльності. Подібна структура дозволяє чітко розмежовувати різні аспекти та компоненти систем штучного інтелекту. Платформа систем штучного інтелекту фактично являється фундаментальним рівнем, представленим апаратно-програмними засобами і є основою для всіх інших рівнів і шарів ШІ в різних аспектах, наприклад, теоретичних, модельних, програмних, прикладних, а також кінцевих сфер застосування. На цьому рівні, завдяки використанню найсучасніших багатоядерних чипів, апаратні компоненти відповідають за виконання обчислень, необхідних для алгоритмів ШІ, а мережеві компоненти реалізують процедури з'єднання та передачі даних, забезпечуючи, тим самим, необхідну обчислювальну потужність. Програмні компоненти платформи включають операційну систему, драйвери, бібліотеки та інші програмні інструменти для

розробки, навчання та виконання алгоритмів і моделей штучного інтелекту, а також забезпечують взаємодію між апаратними сегментами і високорівневими алгоритмами ШІ. Існує ряд платформ і рішень для обробки алгоритмів штучного інтелекту, в основі яких лежать потужні і спеціалізовані процесори, такі, наприклад, як графічні процесори, тензорні процесори та інші. Але, для обробки постійно зростаючих великих даних і складності завдань, що вирішуються системами ШІ, велика увага приділяється створенню нового класу спеціалізованих надпотужних чипів. Для високошвидкісної обробки інформації штучного інтелекту з'явилися сучасні чипи - Azure Maia та Azure Cobalt. Кожен із них включає близько 105 мільярдів транзисторів, причому Cobalt-128 - ядерний процесор, орієнтований для обробки великих даних, а Maia, відповідно, для хмарних обчислень в системах штучного інтелекту. З'явилися також спеціалізовані чипи, такі як нейроморфні процесори, що імітують роботу людського мозку. Ці чипи відкривають нові можливості розробки математичних моделей ШІ, які можуть ефективно використовувати архітектурні особливості таких пристроїв. Зокрема такі процесори підтримують асинхронні обчислення і здатні працювати з низькими енерговитратами, що дозволяє створювати більш біологічно правдоподібні моделі. Сучасні багатоядерні чипи розробляються з урахуванням специфічних вимог ШІ, таких як швидкі операції з матрицями та векторами, що дозволяє більш ефективно синтезувати нові та оптимізувати існуючі математичні моделі. По оцінках вітчизняних і зарубіжних спеціалістів, спільне використання методології синтезу нових математичних моделей і інтелектуальних алгоритмів та спеціалізованих надпотужних чипів для систем ШІ відкриває можливість в декілька раз збільшити продуктивність обчислень, вирішити великий спектр прикладних завдань систем штучного інтелекту, а також оптимально використовувати можливості сучасних процесорів [2-9].

Теоретичні аспекти синтезу математичних моделей штучного інтелекту підвищеної інтелектуальної складності і розмірності, а також інтелектуальних методів обробки великих обсягів даних, представлені другим рівнем архітектури систем штучного інтелекту. Важливо відмітити, що на другому рівні архітектури систем штучного інтелекту сукупність математичних моделей, як основа обробки інтелектуальної інформації, представлена двома класами: математичними моделями для систем штучного інтелекту і математичними моделями навчання систем штучного інтелекту. Перший клас математичних моделей для систем штучного інтелекту орієнтований на виконання відповідної множини конкретних завдань ШІ. Їх основне завдання - забезпечити ефективну роботу системи ШІ в заданих умовах. До них відносяться моделі класифікації, регресії, кластеризації, моделі для обробки природної мови та обробки зображень і інші. Другий клас представляє математичні моделі навчання систем штучного інтелекту. Ці моделі фокусуються на методах навчання та оптимізації систем ШІ. Вони розробляються для того, щоб системи ШІ могли навчатися з даних і покращувати свої результати з часом. Основні компоненти цих моделей включають моделі навчання з учителем і без, моделі регуляризації і узагальнення, моделі кластеризації, зниження розмірності та інші. Акцентуємо увагу на тому, що моделі для систем ШІ використовуються для виконання конкретних складних завдань, тоді як моделі навчання систем ШІ зосереджені на методах та алгоритмах, які дозволяють цим системам навчатися і покращуватися. Вони мають різні цілі і застосування, але разом вони утворюють комплексний підхід до створення ефективних і адаптивних систем штучного інтелекту. Взаємозв'язок між ними полягає в тому, що для розробки ефективної системи ШІ необхідно поєднання обох типів моделей - моделі для виконання завдань і моделі для навчання цих завдань.

Технологічний прорив в сфері синтезу багатоядерних чипів стимулював

інновації у галузі створення та розвитку методів синтезу систем ШІ та інтелектуальних математичних моделей, а швидка еволюція апаратних засобів прискорила процес розробки та впровадження. Стало зрозумілим, що ключові аспекти створення нових математичних моделей штучного інтелекту тісно пов'язані з рівнем розвитку апаратної частини, зокрема із застосуванням сучасних спеціалізованих чипів. Цей факт привів до створення нової методології організації математичних моделей та алгоритмів, які не лише вирішують прикладні завдання ШІ, але й оптимально використовують можливості сучасних чипів. Їх впровадження сприяє прискоренню обчислень, підвищенню енергоефективності, розширенню можливостей мініатюризації та розподілених обчислень. В свою чергу, потужні та доступні обчислювальні ресурси дозволили дослідникам та розробникам створювати нові та покращувати існуючі математичні моделі, що сприяло швидкому прогресу в галузі ШІ. Ряд досліджень в цьому напрямку показали, що у найближчі десятиліття очікується подальше посилення цього взаємозв'язку, оскільки технології апаратного забезпечення продовжуватимуть розвиватися, надаючи все більш потужні та спеціалізовані інструменти для ШІ. Таким чином, прогрес у галузі чипів чинитиме значний вплив на розробку та застосування нових математичних моделей, сприяючи створенню більш ефективних та просунутих систем ШІ.

Третій рівень архітектури систем штучного інтелекту стосується інтелектуальних алгоритмів і програм системного та прикладного характеру. Він є ключовим для забезпечення ефективної роботи. На цьому рівні реалізуються процедури перетворення математичних моделей та методів у вигляді алгоритмів і програм системного та прикладного характеру. Інтелектуальні алгоритми і програми в системах штучного інтелекту охоплюють широкий спектр методів і технологій, які дозволяють комп'ютерному середовищу спільно з комплексом

системних програм виконувати завдання, що зазвичай вимагають людського інтелекту. Програми системного характеру інтегрують апаратні компоненти систем штучного інтелекту, що забезпечує кращу продуктивність і ефективність функціонування, а також реалізують управління ресурсами для обробки у реальному часі великих даних і забезпечення безпеки. Прикладні програми використовують алгоритми ШІ для аналізу даних та надання рекомендацій користувачам розуміння та генерації людської мови, а також використовуються в чат-ботах, системах автоматичного перекладу, аналізу текстів та автономного виконання завдання від імені користувача. Вони застосовуються в бізнесі, медицині, фінансах та інших галузях для аналізу даних. Важливим аспектом третього рівня є взаємодія між інтелектуальними алгоритмами та програмами. Це дозволяє створювати системи, які можуть самонавчатися, адаптуватися до змін та приймати складні рішення на основі аналізу великих обсягів даних.

Четвертий рівень архітектури систем штучного інтелекту фокусується на інтеграції інтелектуальних алгоритмів та програми як основи створення спектру сучасних додатків ШІ, які постійно розвиваються, інтегруючись в різні галузі, включаючи медицину, фінанси, бізнес, маркетинг та багато інших. Загалом, додатки систем штучного інтелекту мають величезний потенціал для покращення різних аспектів життя, підвищення ефективності бізнесу та надання нових можливостей у різних галузях. Вони вже активно використовуються і продовжують розвиватися, надаючи нові інструменти та рішення викликів сучасного світу. Цей рівень демонструє те, як технології ШІ можуть бути застосовані для вирішення конкретних проблем та оптимізації процесів. Найпоширеніші та найважливіші додатки функціонують як чат-боти та віртуальні асистенти, які проводять аналіз медичних зображень, формують сучасну електронну комерцію, реалізують бізнес-аналітику, персоналізовану медицину, створюють контент, аналізують юридичні

документи. Дуже важливими є додатки адаптивного навчання, які спроможні підлаштовувати освітній контент під індивідуальні потреби та здібності учнів, студентів, аспірантів, докторантів та інших спеціалістів. Математичні моделі для систем ШІ сприяють винайденню нових застосувань у всіх сферах соціуму.

### **Диференційні математичні моделі регресивного аналізу для систем штучного інтелекту**

Математичні моделі регресійного аналізу є потужним інструментом в арсеналі систем штучного інтелекту, що дозволяє аналізувати дані, робити прогнози та приймати обґрунтовані рішення на основі числових даних. Моделі використовуються для прогнозування шляхом виявлення залежностей між залежною змінною, яку потрібно передбачити, та однією або декількома новими значеннями незалежних змінних, що використовуються для прогнозування. Фактично регресія — це метод створення математичних моделей для прогнозування значення безперервної числової величини певного об'єкта шляхом використання його характеристик, представлених у вигляді часового ряду. Застосування часових рядів у ШІ-системах охоплює широкий спектр завдань, таких як прогнозування, аналіз тенденцій, аномалій та ін. Регресійні моделі, по суті, передбачають числові характеристики об'єкта, але їх застосування не обмежується тільки прогнозуванням числових значень, вони можуть бути достатньо ефективно використані в інших контекстах. Наприклад, регресійний аналіз допомагає визначити важливість значень різних змінних у прогнозуванні залежної змінної, реалізувати декомпозицію часових рядів, виявляти тренди у даних, а деякі типи регресійних моделей можуть застосовуватися для задач класифікації, прогнозування часу до настання певної події. Тому в ШІ-системах при виконанні широкого спектру прикладних завдань дуже важливу роль відіграють часові ряди. Вони представляють собою послідовність первинних даних

$$x^j(t_{-m}), \dots, x^j(t_{-1}), x^j(t_0), x^j(t_1), \dots, x^j(t_n)$$

кожної  $j^i$  незалежної змінної  $x^j(t)$  аргументу  $t$ , зібраних або зареєстрованих в процесі моніторингу, через рівні інтервали часу  $\Delta t$ . Тобто,  $t_{i+1} = t_i + \Delta t$ ,  $i = 0, 1, 2, \dots, n$ . Незалежні змінні  $x^j(t)$  відображають, як правило, величину  $x^j(t_i)$  кожного  $j^{zo}$  параметру в кожній  $i^u$  точці режиму функціонування складних енергетичних або соціальних об'єктів та

систем. Надзвичайно важливим є те, що формування тимчасових рядів базується на використанні первинної інформації, яка отримується в результаті моніторингу і відображає реальний стан функціонування складного об'єкту будь-якої природи. По оцінкам спеціалістів, використання первинної інформації у вигляді часових рядів

$$x^j(t_{-m}), \dots, x^j(t_{-1}), x^j(t_0), x^j(t_1), \dots, x^j(t_n)$$

є фундаментальним аспектом для побудови ефективних систем ШІ. Завдяки відсутності спотворень первинної інформації, а також перетворень її, забезпечується висока якість даних, що є основою для створення точних моделей. Використання первинних даних, які відображають реальні процеси та

події, дозволяє системам ШІ ефективніше виявляти аномалії або інші нестандартні ситуації, довгострокові тренди та сезонні коливання, що може бути критично важливим для багатьох бізнес-завдань. В умовах швидкозмінного середовища, часові ряди

$$x^j(t_{-m}), \dots, x^j(t_{-1}), x^j(t_0), x^j(t_1), \dots, x^j(t_n),$$

які сформовані на основі первинної інформації, відкривають можливість створювати динамічні моделі, які мають можливість адаптуватися до змін у даних

та забезпечувати оперативність і актуальність, що є критичним для задач в реальному часі. Первинна інформація у вигляді часових рядів

$$x^j(t_{-m}), \dots, x^j(t_{-1}), x^j(t_0), x^j(t_1), \dots, x^j(t_n)$$

використовується для прогнозування цін на акції, валютні курси, обсяг торгівлі, моніторингу споживання і управління виробництвом електроенергії, транспорт-

ними потоками та оптимізації маршрутів. Таким чином, застосування доступних первинних даних, представлених часовими рядами

$$x^j(t_{-m}), \dots, x^j(t_{-1}), x^j(t_0), x^j(t_1), \dots, x^j(t_n),$$

дозволяє ШІ-системам робити достатньо точні та критично важливі для ряду застосувань прогнози, забезпечувати оперативність даних, а також дозволяє створювати більш надійні та адаптивні моделі, які можуть ефективно працювати в реальних умовах і підтримувати прийняття обґрунтованих рішень.

В той же час, робота з часовими рядами в системах штучного інтелекту вимагає використання різноманітних методів та моделей, які можуть враховувати особливості даних та

специфіку завдань, від класичних статистичних підходів до сучасних нейронних мереж та трансформерів. В зв'язку з цим, в рамках цієї роботи, базуючись на фундаментальних поняттях теорії диференціальних перетворень, розглянемо основні аспекти організації диференціальних інноваційно - пізнавальних математичних моделей регресивного аналізу для ШІ-систем, які передбачають значення числових характеристик комплексу параметрів об'єктів будь-якої природи. Пізнавальні моделі регресивного



аналізу відкривають можливість визначати вичерпну інформацію в процесі обробки первинної інформації, представлені

часовими рядами впорядкованих вимірів у вигляді

$$x^j(t_{-m}), \dots, x^j(t_{-1}), x^j(t_0), x^j(t_1), \dots, x^j(t_n),$$

які відображають режими функціонування складних енергетичних та біологічних об'єктів як основи формування нових знань та реалізації процедур імітації творчої діяльності.

Фундаментальні положення теорії диференційних перетворень представлені наступною парою математичних залежностей [2, 10].

$$X_i^j(k) = \frac{H^k}{k!} \left[ \frac{d^k x^j(t_i)}{dt^k} \right]_{t_i} \stackrel{\text{z}}{=} x^j(t_i) = \sum_{k=0}^{k=\infty} \left( \frac{t_i}{H_i} \right)^k X_i^j(k), i = 0, 1, 2, \dots, n, \quad (1)$$

де  $x^j(t)$  - первісна функція  $j^{\text{о}}$  параметра аргументу  $t$ , яка в системах III

представляється у вигляді часового ряду впорядкованих вимірів

$$x^j(t_{-m}), \dots, x^j(t_{-1}), x^j(t_0), x^j(t_1), \dots, x^j(t_n)$$

режимів функціонування складних енергетичних та біологічних об'єктів;  $X_i^j(k)$  - диференційне T-зображення первісної функції  $x^j(t)$ ;  $H_i$  - масштабний коефіцієнт, розмірність якого співпадає з розмірністю аргументу  $t$ , як правило, вибирається на умовах  $0 \leq t \leq H$  на всьому діапазоні функції - оригіналу  $x^j(t)$ ;

$\stackrel{\text{z}}{=}$  - символ відповідності між функцією-оригіналом  $x^j(t)$  і його диференційним T-зображенням  $X_i^j(k)$ . Завдяки прямому диференційному перетворенню, що знаходиться ліворуч від символу  $\stackrel{\text{z}}{=}$ , формується диференційне T-зображення

функції - оригіналу  $x^j(t)$  у вигляді дискретної функції  $X_i^j(k)$  цілочислового аргументу  $k=0, 1, 2, \dots$ . На основі сукупності  $n$  значень T-дискет  $X_i^j(0), X_i^j(1), X_i^j(2) \dots X_i^j(n)$ , функції цілочислового аргументу  $X_i^j(k)$   $k=0, 1, 2, \dots$ , та зворотного диференційного перетворення, що знаходиться праворуч від символу  $\stackrel{\text{z}}{=}$ ,

отримаємо функцію-оригінал  $x^j(t)$ . Відмітимо, що при  $k=0$  згідно (1), для любого миттєвого значення  $t_i$  кожного  $j^{\text{о}}$  параметра  $x^j(t_i)$  виконуються наступні рівності

$$x^j(t_0) = X_0^j(0), x^j(t_1) = X_1^j(0), x^j(t_2) = X_2^j(0), x^j(t_i) = X_i^j(0), x^j(t_r) = X_r^j(0).$$

Застосувавши диференційне перетворення (1), представлене виразом

$$x^j(t_i) = \sum_{k=0}^{k=\infty} \left( \frac{t_i}{H_i} \right)^k X_i^j(k),$$

до отриманої всієї сукупності параметрів  $x^j(t_0), x^j(t_1), x^j(t_2), \dots, x^j(t_i), \dots, x^j(t_r)$  в

кожній точці  $i = 0, 1, 2, \dots, n$ , при  $\tau_0 = 0, \tau_1 = \Delta t, \tau_{i+1} = \tau_i + \Delta t, 0 \leq \tau_i \leq H_i$ ,

$i = 0, 1, 2, \dots, n$ , сформуємо лінійну систему рівнянь  $n^{20}$  порядку, що при  $i = 0$  можна записати у вигляді

$$\begin{aligned} X_0^j(0) + \frac{\tau_1}{H_1} X_0^j(1) + \left(\frac{\tau_1}{H_1}\right)^2 X_0^j(2) + \dots + \left(\frac{\tau_1}{H_1}\right)^n X_0^j(n) &= x^j(t_1) \\ X_0^j(0) + \frac{\tau_2}{H_2} X_0^j(1) + \left(\frac{\tau_2}{H_2}\right)^2 X_0^j(2) + \dots + \left(\frac{\tau_2}{H_2}\right)^n X_0^j(n) &= x^j(t_2) \quad (2) \\ X_0^j(0) + \frac{\tau_n}{H_n} X_0^j(1) + \left(\frac{\tau_n}{H_n}\right)^2 X_0^j(2) + \dots + \left(\frac{\tau_n}{H_n}\right)^n X_0^j(n) &= x^j(t_n). \end{aligned}$$

Необхідно звернути увагу на те, що при такому підході організації обчислювального процесу, величина  $j^{20}$  параметра  $x^j(t)$ , в кожній  $i^u$  точці  $t_i$  представляється не тільки його миттєвим значенням  $x^j(t_i) = X_i^j(0)$  в цій же точці, а також додатково сукупністю Т-дискрет  $X_i^j(1), X_i^j(2), X_i^j(3) \dots X_i^j(k)$ , кожна  $k^a$  із

яких ( $k=1, 2, \dots, n$ ) еквівалентна  $k^u$  похідній  $j^{20}$  параметра  $x^j(t_i)$  в цій же точці  $t_i$ .

Розв'язавши систему рівнянь (2) і враховуючи, що  $x^j(t_i) = X_i^j(0)$ ,  $i = 0, 1, 2, \dots, n$ , отримаємо для всіх миттєвих значень  $t_i$  кожного  $j^{20}$  параметра  $x^j(t_i)$  вектор  $\widetilde{X}_0^j$ , який при  $i = 0$  має вигляд

$$\widetilde{X}_0^j = \left[ X_0^j(0) \mid X_0^j(1) \mid X_0^j(2) \mid \dots \mid X_0^j(n) \right]^t \quad j = 1, 2, \dots, n. \quad (3)$$

Компоненти  $X_0^j(0), X_0^j(1), X_0^j(2) \dots X_0^j(n)$  отриманого вектора  $\widetilde{X}_0^j$ , представленого виразом (3), являються базою для обчислення, в першу чергу, сукупності векторів  $\widetilde{X}_i^j$  при  $i = 1, 2, \dots, n$ , для всіх миттєвих значень  $t_i$  кожного  $j^{20}$  параметра  $x^j(t_i)$ , представленого у вигляді часового ряду  $x^j(t_0), x^j(t_1), \dots, x^j(t_n)$ . Відмітимо, що процедура визначення вектора  $\widetilde{X}_i^j$  при

$i = 1, 2, \dots, n$  на основі відомого вектора  $\widetilde{X}_0^j$  в подальшому реалізується не шляхом розв'язання системи рівнянь (2), а завдяки виконанню матрично-векторної операції, що суттєво оптимізує обчислювальний процес.

Отримані значення компонентів  $X_i^j(0), X_i^j(1), X_i^j(2) \dots X_i^j(n)$  нового вектора

$$\widetilde{X}_i^j = \left[ X_i^j(0) \mid X_i^j(1) \mid X_i^j(2) \mid \dots \mid X_i^j(n) \right]^t$$

$i = 0, 1, 2, \dots, n$  являються базою для формування широкого спектра диференційних інноваційно - пізнавальних математичних моделей. В першу чергу формуються моделі проведення ковзкого моніторингу складних енергетичних

систем будь-якої природи. На основі отриманих результатів відкривається можливість синтезувати диференційні моделі визначення вичерпної інформативності часового ряду первинних даних впорядкованих вимірів

$$x^j(t_{-m}), \dots, x^j(t_{-1}), x^j(t_0), x^j(t_1), \dots, x^j(t_n).$$

Вектор  $\widetilde{X}_i^j$  являється базою для синтезу моделей прогнозування значень незалежних та залежних змінних, моделей ШІ, та проведення сукупності завдань

регресивного аналізу, диференційних математичних моделей кореляційного аналізу і ряду диференційних моделей

прогнозу ваги і зміщення в нейромережах ШІ-систем.

**Організація ковзкого моніторингу**

Проведення в реальному часі ковзкого моніторингу за допомогою

сукупності миттєвих значень  $t_i$  кожного  $j^{20}$  параметра  $x^j(t_i)$ , що представляються у вигляді часового ряду  $x^j(t_0), x^j(t_1), \dots, x^j(t_n)$ , може бути реалізовано шляхом визначення вектора

$$\widetilde{X}_i^j = \begin{bmatrix} X_i^j(0) & X_i^j(1) & X_i^j(2) & \dots & X_i^j(n) \end{bmatrix}^t$$

$i = 1, 2, \dots, n$ , на основі вчисленого, згідно виразу (2), вектора

$$\widetilde{X}_0^j = \begin{bmatrix} X_0^j(0) & X_0^j(1) & X_0^j(2) & \dots & X_0^j(n) \end{bmatrix}^t.$$

Детальний аналіз процедур формування диференційних математичних моделей, представлених виразами (1), (2), відкрив можливість зробити наступний висновок. Якщо обчислювальний процес, згідно математичної моделі (2), реалізувати

при умові  $H = H_i \ i = 0, 1, 2, \dots, n$ , а значення незалежних змінних  $x^j(t)$ , представлених у вигляді часового ряду впорядкованих вимірів

$$x^j(t_{-m}), \dots, x^j(t_{-1}), x^j(t_0), x^j(t_1), \dots, x^j(t_n)$$

знаходяться один від одного на однаковій відстані  $\Delta t$ , то кожний наступний вектор

$$\widetilde{X}_{i+1}^j = \begin{bmatrix} X_{i+1}^j(0) & X_{i+1}^j(1) & X_{i+1}^j(2) & \dots & X_{i+1}^j(n) \end{bmatrix}^t,$$

пов'язаний з попереднім вектором

$$\widetilde{X}_{i-1}^j = \begin{bmatrix} X_{i-1}^j(0) & X_{i-1}^j(1) & X_{i-1}^j(2) & \dots & X_{i-1}^j(n) \end{bmatrix}^t$$

наступною математичною залежністю

$$\Pi \widetilde{X}_{i-1}^j = \widetilde{X}_i^j = \Pi^{-1} \widetilde{X}_{i+1}^j \tag{4}$$

в якій  $\Pi$ ,  $\Pi^{-1}$  – пряма і зворотна матриці Паскаля, оскільки компоненти їх рівні числам, що формують трикутник Паскаля

[10]. Пряма матриця Паскаля  $\Pi$  і зворотна матриця Паскаля  $\Pi^{-1}$  формується наступним чином

$$\Pi = \begin{bmatrix} 1 & 1 & 1 & 1 & 1 & . \\ . & 1 & 2 & 3 & 4 & . \\ . & . & 1 & 3 & 6 & . \\ . & . & . & 1 & 4 & . \\ . & . & . & . & 1 & . \end{bmatrix}$$

$$\Pi^{-1} = \begin{bmatrix} 1 & -1 & 1 & -1 & 1 & . \\ . & 1 & -2 & 3 & -4 & . \\ . & . & 1 & -3 & 6 & . \end{bmatrix}$$

			1	-4	.
				1	.

При такому підході, в процесі організації обчислювального процесу, необхідність розв'язання системи рівнянь

(2) для визначення вектора  $\widetilde{X}_0^j$ , згідно (3), з'являється тільки один раз, при  $i = 0$ . В подальшому, кожний новий вектор

$$\widetilde{X}_i^j = \left[ X_i^j(0) \mid X_i^j(1) \mid X_i^j(2) \mid \dots \mid X_i^j(n) \right]^t$$

$i = 1, 2, \dots, n$ , обчислюється не шляхом вирішення системи рівнянь (2) в кожній наступній  $i^{\text{й}}$   $i = 1, 2, \dots, n$  точці, а завдяки реалізації операції перемноження матриці на вектор  $\text{П}\widetilde{X}_{i-1}^j = \widetilde{X}_i^j$ , згідно виразу (4). Така організація ковзкого моніторингу суттєво спрощує організацію обчислювального процесу.

### Визначення вичерпної інформативності

На основі отриманих  $n$  компонентів  $X_i^j(0), X_i^j(1), X_i^j(2) \dots X_i^j(n)$ , нового вектора

$$\widetilde{X}_i^j = \left[ X_i^j(0) \mid X_i^j(1) \mid X_i^j(2) \mid \dots \mid X_i^j(n) \right]^t,$$

вчисленого згідно виразів (2) і (4), відкривається можливість визначати всю глибину інформативності первинних даних

незалежних змінних  $x^j(t_i)$ , представлених числовим рядом

$$x^j(t_{-m}), \dots, x^j(t_{-1}), x^j(t_0), x^j(t_1), \dots, x^j(t_n).$$

Для організації обчислювального процесу, визначення всієї глибини інформативності і враховуючи, що  $x^j(t_i) = X_i^j(0)$ , введемо позначення  $\tau_0 = 0$ ,  $\tau_1 = \Delta t$ ,  $\tau_{i+1} = \tau_i + \Delta t$ ,  $\tau_i = -H_i$ ,

$i = 1, 2, \dots, n$ , та використаємо зворотне диференційне перетворення (1), представлене наступним чином

$$x^j(t_i) = \sum_{k=0}^{k=\infty} \left(\frac{\tau_i}{H_i}\right)^k X_i^j(k), \quad \text{запишемо систему математичних залежностей}$$

$$\begin{aligned} |x^j(t_{-1}) - \sum_{k=0}^n (-1)^k X_0^j(k)| &\leq \varepsilon_1 \\ |x^j(t_{-i}) - \sum_{k=0}^n (-1)^k X_i^j(k)| &\leq \varepsilon_2 \\ |x^j(t_{-n}) - \sum_{k=0}^n (-1)^k X_n^j(k)| &\leq \varepsilon_n, \end{aligned} \quad (5)$$

де  $\varepsilon_i$  – величина, яка характеризує точність визначення вичерпної інформативності. У тому випадку, коли система нерівностей (5) не виконується, тоді необхідно, згідно з виразами (2), (4), додатково обчислити  $m$  дискрет  $X_i^j(n+m)$  для виконання умов (5). Такий підхід до організації обчислювальних процесів одночасної обробки, як миттєвих значень  $x^j(t_i)$ , так і дискрет  $X_i^j(k)$ ,  $i = 0, 1, 2, \dots, n$ , відкриває

додаткові можливості отримання всієї глибини інформативності даних, представлених числовим рядом  $x^j(t_{-m}), \dots, x^j(t_{-1}), x^j(t_0), x^j(t_1), \dots, x^j(t_n)$ , як основи формування диференційних інноваційно-пізнавальних моделей штучного інтелекту.

### Моделі прогнозування значень незалежних і залежних змінних

Прогнозування значень  $x^j(t_{n+1}), x^j(t_{n+2}), \dots, x^j(t_{2n})$ , часового ряду  $x^j(t_{-m}), \dots, x^j(t_{-1}), x^j(t_0), x^j(t_1), \dots, x^j(t_n)$  впорядкованих вимірів незалежних змінних  $x^j(t)$  аргументу  $t$ , для проведення широкого спектру завдань

регресивного аналізу може бути реалізовано наступним чином. Використавши  $n$  компонентів  $X_i^j(0), X_i^j(1), X_i^j(2) \dots X_i^j(n)$  визначеного, згідно (4), вектора

$$\widetilde{X}_i^j = \begin{bmatrix} X_i^j(0) & X_i^j(1) & X_i^j(2) & \dots & X_i^j(n) \end{bmatrix}^t,$$

та скориставшись зворотним диференційним перетворенням

$$x^j(t_i) = \sum_{k=0}^{k=\infty} \left(\frac{\tau_i}{H_i}\right)^k X_i^j(k),$$

сформуємо диференційну математичну модель прогнозу значень

$$x^j(t_{n+1}), x^j(t_{n+2}), \dots, x^j(t_{2n})$$

незалежних змінних  $x^j(t)$ , представлених часовим рядом

$$x^j(t_{-m}), \dots, x^j(t_{-1}), x^j(t_0), x^j(t_1), \dots, x^j(t_n)$$

впорядкованих вимірів в моменти часу

$$t_{n+1} = (n + 1)\Delta t, t_{n+2} = (n + 2)\Delta t, \dots, t_{2n} = 2n\Delta t.$$

$$\begin{aligned} x^j(t_{n+1}) &= \sum_{k=0}^{k=n} \left(\frac{\tau_{n+1}}{H_{n+1}}\right)^k X_i^j(k) \\ x^j(t_{n+2}) &= \sum_{k=0}^{k=n} \left(\frac{\tau_{n+2}}{H_{n+2}}\right)^k X_i^j(k) \\ x^j(t_{2n}) &= \sum_{k=0}^{k=n} \left(\frac{\tau_{2n-1}}{H_{2n}}\right)^k X_i^j(k). \quad i = 0, 1, 2, \dots, n \end{aligned} \quad (6)$$

Не важко бачити, що, поступаючи по аналогії з вищеописаним, можна синтезувати диференційні моделі прогнозу залежних змінних  $y^j(t)$  в тому випадку, коли є деяка сукупність значень, представлених часовим рядом

$$y^j(t_{-v}), \dots, y^j(t_{-1}), y^j(t_0), y^j(t_1), \dots, y^j(t_\omega),$$

тобто з урахуванням історичних даних. Визначення  $\omega$  прогнозованих значень

$$y^j(t_{\omega+1}), y^j(t_{\omega+2}), \dots, y^j(t_{2\omega})$$

залежної змінної  $y^j(t)$  в кожній  $t_{\omega+l}$  точці  $l = 1, 2, \dots, \omega$  може бути реалізовано наступним чином

$$y^j(t_{\omega+l}) = \sum_{k=0}^{k=n} \left(\frac{\tau_{\omega+l}}{H_{\omega+l}}\right)^k Y_i^j(k), \quad l = 1, 2, \dots, \omega. \quad (7)$$

**Диференційні математичні моделі регресивного аналізу ШІ-систем**

Математичні моделі регресивного аналізу використовуються для виявлення залежності між змінними та передбачення значень однієї змінної на основі значень інших змінних. Регресійний аналіз є потужним інструментом для виявлення і кількісної оцінки взаємозв'язків між змінними, а також для передбачення їх майбутніх значень.

Розглянемо методи організації диференційних математичних моделей регресивного аналізу для обробки інформації в системах штучного інтелекту. Завдяки організації обчислень, на основі диференційних математичних моделей, шляхом одночасної обробки як миттєвих значень  $x^j(t_i)$  незалежних змінних, представлених у вигляді часових рядів

$$x^j(t_{-m}), \dots, x^j(t_{-1}), x^j(t_0), x^j(t_1), \dots, x^j(t_n)$$

впорядкованих вимірів, так і їх

$$T\text{-дискрет } X_i^j(k), \quad i = 0, 1, 2, \dots, n,$$

відкривається можливість суттєво покращити якість визначення домінуючих характеристик, а також створювати

$$\widetilde{X}_i^j = \left[ X_i^j(0) \mid X_i^j(1) \mid X_i^j(2) \mid \dots \mid X_i^j(n) \right]^t.$$

Компоненти  $X_i^j(0), X_i^j(1), X_i^j(2) \dots X_i^j(n)$  вектора  $\widetilde{X}_i^j$  є основою синтезу диференційної лінійної моделі регресії  $y = \beta_0 + \beta_1 x$ , представленої в області диференційних зображень як

$$y^j(t_{n+l}) = \beta_0(0) + \beta_1(0) \sum_{k=0}^{t_{n+l}} \left( \frac{t_{n+l}}{H_{n+l}} \right)^k X_i^j(k), \quad l = 1, 2, \dots, n. \quad (8)$$

Проаналізувавши вираз (8), можна зробити висновок, що на основі компонент  $X_i^j(0), X_i^j(1), X_i^j(2) \dots X_i^j(n)$  вектора  $\widetilde{X}_i^j$  можна достатньо ефективно отримати  $n$  прогнозованих значень  $y^j(t_{n+1}), y^j(t_{n+2}), \dots, y^j(t_{2n})$  залежної змінної  $y^j(t)$  в кожній  $t_{n+l}$  точці  $l = 1, 2, \dots, n$ . Відмітимо, що на основі вичисленого вектора  $\widetilde{X}_i^j$ , кожний наступний вектор  $\widetilde{X}_{i+1}^j$  може бути визначений на основі виразу (4), що суттєво спрощує обчислювальний процес.

динамічні моделі, які мають можливість адаптуватися до змін у даних. Основні типи регресійних моделей включають лінійну регресію, поліноміальну регресію, логістичну регресію та інші. Розглянемо методи формування диференційних математичних моделей, деяких із них детальніше.

**Лінійна модель регресії**

представлена у вигляді  $y = \beta_0 + \beta_1 x$ , де  $\beta_0$  - вільний член;  $\beta_1$  - коефіцієнт нахилу;  $y^j(t)$  - залежна змінна;  $x$  - незалежна змінна. Для формування диференційної моделі лінійної регресії представимо сукупність миттєвих значень незалежної змінної  $x^j(t_i)$  у вигляді часового ряду впорядкованих вимірів

$$x^j(t_{-m}), \dots, x^j(t_{-1}), x^j(t_0), x^j(t_1), \dots, x^j(t_n).$$

Враховуючи, що на основі диференційних перетворень (1), значення  $\beta_0, \beta_1$  представляються у вигляді

$$\beta_0(0) \mp \beta_0, \quad \beta_1(0) \mp \beta_1, \quad \text{а } x^j(t_i) = X_i^j(0),$$

то по аналогії з (2) формується система рівнянь, рішенням якої є вектор

**Множинна лінійна регресія**

Модель використовується, коли залежна змінна у залежить від декількох незалежних змінних  $x_1, x_2, \dots, x_m$ , що може бути записано у вигляді

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_m x_m.$$

Згідно аналогії вищеописаного, для кожної  $r^j \quad r = 1, 2, \dots, m$  незалежної змінної  $x^{jr}(t_i)$ ,  $j^{\text{го}}$  параметру, представленої у вигляді часового ряду

$$x^{jr}(t_{-m}), \dots, x^{jr}(t_{-1}), x^{jr}(t_0), x^{jr}(t_1), \dots, x^{jr}(t_n)$$

впорядкованих вимірів, сформуємо згідно виразу (2) вектор (3), наступним чином:

$$\widetilde{X}_i^{jr} = \begin{bmatrix} X_i^{jr}(0) & X_i^{jr}(1) & X_i^{jr}(2) & \dots & X_i^{jr}(n) \end{bmatrix}^t.$$

На основі отриманих компонентів  $X_i^{jr}(0), X_i^{jr}(1), X_i^{jr}(2), \dots, X_i^{jr}(n)$ , вектора  $\widetilde{X}_i^{jr}$ , можна записати диференційну модель множинної лінійної регресії у вигляді

$$y^j(t_{n+l}) = \beta(0) + \sum_r^m \beta_r \sum_{k=0}^{t_{n+l}} \left( \frac{t_{n+l}}{H_{n+l}} \right)^k X_0^{jr}(k), j=1,2,\dots,n, r=1,2,\dots,m. \quad (9)$$

Математична диференційна модель, представлена виразом (9), являється базою для визначення  $n$  прогнозованих значень  $y^j(t_{n+1}), y^j(t_{n+2}), \dots, y^j(t_{2n})$  змінної

$y^j(t)$ , яка залежить від  $m$  незалежних змінних  $x^{jr}(t_i)$ , представлених часовим рядом

$$x^{jr}(t_{-m}), \dots, x^{jr}(t_{-1}), x^{jr}(t_0), x^{jr}(t_1), \dots, x^{jr}(t_n)$$

впорядкованих вимірів.

Розглянемо випадок, коли у виразі  $y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_m x_m$  в якості вільного члена  $\beta_0$  і коефіцієнтів  $\beta_r$  використовуються функції  $\beta_0(t)$  та  $\beta_r(t)$ . Представимо  $\beta_0(t), \beta_r(t)$  у вигляді часових рядів впорядкованих вимірів відповідно

$\beta_0(t_{-m}), \dots, \beta_0(t_{-1}), \beta_0(t_0), \beta_0(t_1), \dots, \beta_0(t_n)$ , і  $\beta_r(t_{-m}), \dots, \beta_r(t_{-1}), \beta_r(t_0), \beta_r(t_1), \dots, \beta_r(t_n)$ ,  $r=1,2,\dots,m$ . Операція перемноження  $Z_r(t) = \beta_r x_r$  в області диференційних зображень представляється наступною математичною залежністю [10].

$$Z_r(t) = \beta_r x_r \mp Z_r(k) = \sum_{l=0}^{l=k} \beta_r(l) X_r(k-l), \quad (10)$$

$l=1,2,\dots,n, r=1,2,\dots,m$  або у розгорнутому вигляді як

$$\begin{aligned} Z_r(0) &= \beta_r(0) X_r(0) \\ Z_r(1) &= \beta_r(0) r(1) + \beta_r(1) X_r(0) \\ Z_r(2) &= \beta_r(0) X_r(2) + \beta_r(1) X_r(1) + \beta_r(2) X_r(0). \end{aligned} \quad (11)$$

$$r=1,2,\dots,m, \quad l=1,2,\dots,n$$

Диференційна модель, визначення  $n$  прогнозованих значень  $y^j(t_{n+1}), y^j(t_{n+2}), \dots, y^j(t_{2n})$  залежної змінної  $y^j(t)$ , з урахуванням, що  $\beta_0(t), \beta_r(t)$  представлені функціями, а також для випадку, коли  $t_l = H_l$ , може бути записана у вигляді

$$y^j(t_{n+l}) = \beta(0) + \sum_{r=1}^m \beta_r \sum_{l=0}^{l=k} \beta_r(l) X_r(k-l). \quad (12)$$

$$r=1,2,\dots,m, \quad l=1,2,\dots,n$$

Наведені диференційні моделі регресивного аналізу є базою для прогнозу  $n$  значень

$$y^j(t_{n+1}), y^j(t_{n+2}), \dots, y^j(t_{2n})$$

залежних змінних  $y^j(t_{n+l}), l=1,2,\dots,n$ , а при необхідності можуть бути використані для визначення прогнозованих величин залежних змінних.

**Диференційні математичні моделі кореляційного аналізу в ШІ-системах**

Методи кореляційного аналізу відносяться до класу статистичних і є важливим інструментом при роботі з моделями ШІ. Вони використовуються

$$x^j(t_{-m}), \dots, x^j(t_{-1}), x^j(t_0), x^j(t_1), \dots, x^j(t_n) \quad j= 1, 2, \dots, n,$$

представленими у вигляді часових рядів. У контексті штучного інтелекту, цей аналіз часто застосовується для виявлення змінних, що впливають одна на одну і в якому ступені. Це корисно для відбору важливих ознак, які будуть використовуватися в моделі. В процесі побудови інтелектуальних моделей важливо знати, які ознаки є найбільш значущими. Висока кореляція між ознакою і цільовою змінною свідчить не тільки про її важливість, а також сигналізує про можливість негативно вплинути на

для виявлення та оцінки ступеня взаємозв'язку між залежними змінними  $y^j(t_{n+1}), y^j(t_{n+2}), \dots, y^j(t_{2n})$ , які ми прогнозуємо, а також між незалежними змінними

стабільність і інтерпретацію моделі штучного інтелекту. Завдяки кореляційному аналізу відкривається можливість ідентифікувати такі випадки, щоб їх можна було усунути, наприклад, видаленням однієї з корельованих змінних. Результати кореляційного аналізу являються основою покращення якості інтелектуальних моделей та забезпечити більш точні прогнози.

Для зручності, запишемо у вигляді часових рядів сукупність незалежних змінних

$$x^j(t_0), x^j(t_1), \dots, x^j(t_i), \dots,$$

а також залежних змінних

$$y^j(t_0), y^j(t_1), \dots, y^j(t_s), \dots$$

у наступному вигляді

$$x_0^j, x_1^j, x_2^j \dots x_i^j \dots$$

та залежних відповідно

$$y_0^j, y_1^j, y_2^j \dots y_s^j \dots,$$

$i = 0, 1, 2, \dots, s=0, 1, 2, \dots, j= 1, 2, \dots$  На практиці, використовуються функції автокореляції

$$r_A(x_i^j, x_{i+l}^j) = \frac{1}{N} \sum_{i=1}^N x_i^j x_{i+l}^j,$$

та функції взаємкореляції

$$r_B(x_i^j, x_{i+l}^j) = \frac{1}{N} \sum_{i=1}^N x_i^j x_{i+l}^j.$$

Автокореляційна функція допомагає визначити структуру залежностей у часі, в межах одного часового ряду, залежних

$$y_0^j, y_1^j, y_2^j \dots y_s^j \dots$$

і незалежних

$$x_0^j, x_1^j, x_2^j \dots x_i^j \dots$$

змінних. Вона корисна для аналізу сезонних та трендових компонентів.

Взаємкореляційна функція, використовується для виявлення залежностей між двома часовими рядами

$$y_0^j, y_1^j, y_2^j \dots y_s^j \dots$$

та

$$y_0^{j+n}, y_1^{j+n}, y_2^{j+n} \dots y_s^{j+n} \dots,$$

що корисно в контексті аналізу впливу одного ряду на інший. Наприклад, у моделях передбачення або причинно-



наслідкового аналізу. Для незалежних змінних  $x_0^j, x_1^j, x_2^j \dots x_i^j \dots$ , реалізуємо процедуру (2), а потім, відповідно,

процедуру (11), завдяки чому вичислимо  $n$  векторів

$$\widetilde{X}_i^j = \left[ X_i^j(0) \mid X_i^j(1) \mid X_i^j(2) \mid \dots \mid X_i^j(n) \right]^t \quad i = 1, 2, \dots, n.$$

Компоненти вектора  $\widetilde{X}_i^j$  є основою для організації диференційних математичних моделей кореляційного аналізу в ШІ-

системах. Диференційні моделі автокореляційної і взаємкореляційної функцій в області диференційних зображень можуть бути записані у вигляді

$$R_A(k) = \frac{1}{N} \sum_{i=1}^N \sum_{m=0}^{m=k} X_i^j(m) X_{i+l}^j(k-m), \quad (13)$$

$$R_B(k) = \frac{1}{N} \sum_{i=1}^N \sum_{m=0}^{m=k} X_i^j(m) X_{i+s}^{j+n}(k-m). \quad k = 0, 1, 2, \dots$$

Після обчислення, згідно виразу (13), відповідної кількості дискрет  $R_A(0), R_A(1), R_A(2), \dots$  автокореляційної функції  $R_A(k)$ , а також сукупності дискрет  $R_B(0), R_B(1), R_B(2), \dots$  взаємкореляційної

функції  $R_B(k)$  і застосувавши зворотне диференціальне перетворення (1), отримаємо значення автокореляційної  $r_A(x_i^j, x_{i+l}^j)$  та взаємкореляційної  $r_B(x_i^j, x_{i+l}^j)$  функцій в наступному вигляді

$$R_A(x_i^j, x_{i+l}^j) = R_A(0) + R_A(1) \frac{t}{H_1} + R_A(2) \frac{t^2}{H_2^2} + \dots \quad (14)$$

$$R_B(x_i^j, x_{i+l}^j) = R_B(0) + R_B(1) \frac{t}{H_2} + R_B(2) \frac{t^2}{H_2^2} + \dots$$

### Диференційні моделі прогнозу ваги і зміщення в ШІ-системах

Процес навчання нейромережі зводиться до пошуку оптимальних значень ваг  $\omega$  (weights) і зміщень  $b$  (biases). Ваги є основними параметрами, які визначають силу зв'язків між нейронами в мережі. Кожен зв'язок має свою вагу, яка визначає вплив вхідного сигналу на вихідний. Під час навчання ваги коригуються, щоб зменшити помилку передбачень моделі. Зміщення є додатковими параметрами, які додаються до кожного нейрона перед застосуванням активаційної функції. Вони допомагають зсунути активаційну функцію вліво або вправо, що дозволяє моделі краще підлаштуватися під дані. Навчання нейронних мереж є складним і багатогранним процесом, який включає велику кількість ключових аспектів. Кожен з них вносить свій внесок у загальну складність і для реалізації вимагає глибоких знань і досвіду, а також

міждисциплінарного підходу, який включає знання в області машинного навчання, програмування, статистики та прикладної математики. Ідея формування ваг і зміщень в нейромережі шляхом їх прогнозування, замість традиційного процесу оптимізації (навчання), є цікавим підходом. Прогнозування ваг і зміщень, з урахуванням історичних даних, тобто використання методів, які передбачають ваги на основі попереднього навчання або схожих задач, означає, що ми намагаємося передбачити найкращі значення цих параметрів заздалегідь, без ітеративного процесу. Такий підхід може допомогти уникнути перенавчання шляхом запобігання надмірному налаштуванню моделі на дані навчання, використовуючи попередні прогнози як орієнтири. Застосування попередньо прогнозованих параметрів може значно прискорити початкову фазу навчання, дозволяючи моделі починати з більш сприятливих ваг і

зміщень. У випадках, коли нова задача подібна до попередніх задач, використання статистичних даних про параметри може допомогти процедурі перенесення частини знань. Якщо дані для нової задачі обмежені, прогнозовані параметри можуть дати стартову точку, яка менш залежна від великої кількості нових. В зв'язку з цим, з'являється необхідність в розробці математичних моделей, методів і алгоритмів для прогнозування параметрів нейромережі на основі історичних даних. Нові пізнавальні моделі, орієнтовані для прогнозу значень ваг, можуть суттєво поліпшити процес навчання нейронних мереж, зокрема шляхом прискорення навчання, покращення якості моделі, адаптації до нових даних, економії ресурсів, підвищення загальної продуктивності та суттєво збільшити точність і ефективність функціонування, що має велике значення.

Фундаментальним процесом, що відбувається під час проходження сигналу через нейронну мережу, є передавання даних між її шарами, що ефективно представлені в матрично-векторній формі. Такий підхід дозволяє ефективно виконувати обчислення для кожного  $l^{eo}$  шару мережі і включає декілька етапів. На першому етапі реалізується лінійне перетворення вхідного вектора за допомогою матриці  $W^l$  ваг. На наступному етапі реалізується додавання зміщення, а на кінцевому етапі відповідно застосовується функція активації. Кожен  $l^i$  шар отримує вхідні дані у вигляді вектора  $X^{(l-1)}$ , перетворює їх за допомогою матриці ваг  $W^l$  та передає результат наступному шару. Для кожного  $l^{eo}$  шару нейронної мережі процес передавання даних виглядає наступним чином:

$$X^l = W^l X^{(l-1)} + b^l, \quad l=1,2,\dots,r, \quad (15)$$

де  $W^l$  - матриця ваг, яка містить ваги всіх зв'язків між нейронами  $l^{eo}$  шару. Якщо  $l^i$  шар має  $m$  вихідних нейронів і приймає  $n$

вхідних сигналів, то матриця представлена у наступному вигляді:

$$W^l = \begin{array}{|c|c|c|c|c|} \hline \omega_{11}^l & \omega_{12}^l & \omega_{13}^l & \dots & \omega_{1n}^l \\ \hline \omega_{21}^l & \omega_{22}^l & \omega_{23}^l & \dots & \omega_{2n}^l \\ \hline \omega_{31}^l & \omega_{32}^l & \omega_{33}^l & \dots & \omega_{3n}^l \\ \hline \dots & \dots & \dots & \dots & \dots \\ \hline \omega_{m1}^l & \omega_{m2}^l & \omega_{m3}^l & \dots & \omega_{mn}^l \\ \hline \end{array}$$

$i=1,2,3,\dots,n, \quad j=1,2,3,\dots,m$ , має розмір  $m \times n$ , а стрічки її формуються відповідно

$(\omega_{11}, \omega_{12}, \dots, \omega_{1n}), (\omega_{21}, \omega_{22}, \dots, \omega_{2n}), \dots$   
 $(\omega_{m1}, \omega_{m2}, \dots, \omega_{mn}); X^{(l-1)}$  — вхідний вектор

$$X^{(l-1)} = \begin{array}{|c|c|c|c|c|} \hline X_1^l & X_2^l & X_3^l & \dots & X_n^l \\ \hline \end{array}^t$$

$l^{eo}$  шару розміром  $n$  (тобто вихід активованого значення з попереднього  $(l-1)^{eo}$  шару);  $X^l$  — вихідний вектор

$$X^l = \begin{array}{|c|c|c|c|c|} \hline X_1^l & X_2^l & X_3^l & \dots & X_m^l \\ \hline \end{array}^t,$$

розміром  $m$  (вихід активованого значення з поточного  $l^{eo}$  шару);  $b^l$  — вектор зміщень для  $l^{eo}$  шару;  $r$  — число шарів нейромережі.

Для кожного  $l^{eo}$  шару формується своя матриця ваг  $W^l$ , в якій кожен рядок

представляє ваги, пов'язані з одним нейроном. Після обчислення лінійної комбінації  $W^l X^{(l-1)} + b^l$  застосовується активаційна функція  $\sigma$ , щоб ввести нелінійність у моделі.

Передавання даних між шарами нейронної мережі, представлених в матрично-векторній формі, дозволяє ефективно обчислювати лінійні перетворення, додавати зміщення та застосовувати активаційні функції. Це основний процес, що відбувається при проходженні сигналу через нейронну мережу, і він забезпечує можливість моделювання складних залежностей у даних. Використання матриць і векторів для організації обчислювальних процесів в нейронних мережах дозволяє виконувати обчислення паралельно та реалізувати процедури прогнозу значень ваг  $\omega_{ij}^l$ , елементів матриці  $W^l$ , що дуже важливо, при організації обчислень в нейромережах з великим числом параметрів. Методи прогнозування, з урахуванням історичних даних, передбачають ваги на основі попереднього навчання або схожих задач. Використання статистичних даних про параметри нейромережі відкриває можливість реалізувати процедуру переносу частини отриманих раніше

попередніх знань. Визначення і коригування ваг  $\omega_{ij}^l$ , представлених елементами матриці  $W^l$ , що відображає всі зв'язки між нейронами кожного  $l^{eo}$  шару нейромережі, є центральним аспектом в процесі навчання нейронної мережі. Для реалізації прогнозу значень ваг  $\omega_{ij}^l$ , синтезуємо диференційні математичні моделі. Для цього представимо у вигляді часових рядів  $\omega_{ij}^l(t_0), \omega_{ij}^l(t_1), \omega_{ij}^l(t_2), \dots, \omega_{ij}^l(t_p)$ , сукупність величини ваг  $\omega_{ij}^l$  кожного елемента матриці  $W^l$ , обчислених на основі  $p$  попередніх ітерацій налаштування параметрів нейромережі.

Диференційні моделі, визначення прогнозу значень параметрів  $\omega_{ij}^l(t_{p+1}), \omega_{ij}^l(t_{p+2}), \omega_{ij}^l(t_{p+3}), \dots$ , базуються на статистичних даних  $\omega_{ij}^l(t_0), \omega_{ij}^l(t_1), \omega_{ij}^l(t_2), \dots, \omega_{ij}^l(t_p)$ . Використавши зворотне диференційне перетворення (1), представлене виразом  $\omega_{ij}^s(t) = \sum_{k=0}^{k=n} \left(\frac{t_s}{H_s}\right)^k W_{ij}^s(k)$ , запишемо, для кожного  $l^{eo}$  шару, по аналогії з (2), наступну систему рівнянь

$$W_{ij}^s(0) + \frac{\tau_1}{H_1} W_{ij}^s(1) + \left(\frac{\tau_1}{H_1}\right)^2 W_{ij}^s(2) + \dots + \left(\frac{\tau_1}{H_1}\right)^p W_{ij}^s(p) = \omega_{ij}^s(t_1)$$

$$W_{ij}^s(0) + \frac{\tau_p}{H_p} W_{ij}^s(1) + \left(\frac{\tau_p}{H_p}\right)^2 W_{ij}^s(2) + \dots + \left(\frac{\tau_p}{H_p}\right)^p W_{ij}^s(p) = \omega_{ij}^s(t_p). \quad (16)$$

Рішення системи рівнянь (16) представляється у вигляді наступного вектора виду

$$\widetilde{W}_{ij}^s = \left[ \overline{W}_{ij}^s(0) \mid \overline{W}_{ij}^s(1) \mid \overline{W}_{ij}^s(2) \mid \dots \mid \overline{W}_{ij}^s(p) \right]^t.$$

Компоненти  $W_{ij}^s(0), W_{ij}^s(1), W_{ij}^s(2), \dots, \overline{W}_{ij}^s(p)$  вектора  $\widetilde{W}_{ij}^s$  є основою синтезу диференційної математичної моделі виду

$$\omega_{ij}^s(t_{p+1}) = \sum_{k=0}^{k=p} \left(\frac{t_{p+1}}{H_{p+1}}\right)^k W_{ij}^s(k)$$

$$\omega_{ij}^s(t_{p+2}) = \sum_{k=0}^{k=p} \left(\frac{t_{p+2}}{H_{p+2}}\right)^k W_{ij}^s(k) \quad (17)$$

$$\omega_{ij}^s(t_{2p}) = \sum_{k=0}^{k=p} \left(\frac{t_{2p}}{H_{2p}}\right)^k W_{ij}^s(k),$$

орієнтованої для прогнозу значень ваг  $\omega_{ij}^l(t_{p+1}), \omega_{ij}^l(t_{p+2}), \omega_{ij}^l(t_{p+3})$  матриці  $W^l$  кожного  $l^{eo}$  шару нейромережі.

Результати проведеного аналізу проблеми масового використання штучного інтелекту відкрили можливість

використання фундаментальних понять теорії диференційних перетворень для синтезу спектру диференційних інноваційно - пізнавальних математичних моделей штучного інтелекту.

## Висновки

1. Проведено аналіз багатогранної проблеми еволюції масового використання штучного інтелекту як однієї з ключових, революційних технологій сучасності. Базуючись на теорії диференційних перетворень, обґрунтовано напрямки наукових досліджень, пов'язаний зі створенням наукових засад синтезу інноваційно - пізнавальних математичних моделей штучного інтелекту, орієнтованих для визначення вичерпної інформативності впорядкованих вимірів режимів функціонування складних енергетичних та біологічних об'єктів і на їх основі забезпечення можливості формування нових знань, реалізації процедур імітації творчої діяльності та формування інтелектуальних технологій, орієнтованих на корінне перетворення концепцій та форматів функціонування соціально-економічних систем усіх рівнів.

2. Базуючись на фундаментальних поняттях теорії диференційних перетворень, запропоновано методологію синтезу диференційних математичних моделей для аналізу і прогнозу нових значень залежних змінних  $y^j(t_{n+1}), y^j(t_{n+2}), \dots, y^j(t_{2n})$  та незалежних змінних  $x^j(t_{n+1}), x^j(t_{n+2}), \dots, x^j(t_{2n})$ , формування яких базується на використанні представлених у вигляді часового ряду відомих попередніх значень  $x^j(t_{-m}), \dots, x^j(t_{-1}), x^j(t_0), x^j(t_1), \dots, x^j(t_n)$  первинних даних, отриманих в результаті моніторингу складних об'єктів будь-якої природи.

3. Запропоновано сукупність диференційних математичних моделей підвищеної інтелектуальної складності і розмірності для проведення регресивного аналізу в системах штучного інтелекту з метою виявлення залежності між змінними та передбачення значень однієї змінної на основі значень незалежних змінних, представлених у вигляді часового ряду впорядкованих вимірів, наведено ряд диференційних моделей лінійної регресії і множинної лінійної регресії, коли змінна залежить від декількох незалежних змінних та показано застосування матриць Паскаля

для організації обчислювального процесу при реалізації ковзкого моніторингу.

4. Показано, що фундаментальним процесом, що відбувається під час проходження сигналу через нейронну мережу є процедура представленої інформації в матрично-векторній формі та подальше передавання її між шарами нейронної мережі, завдяки такому підходу відкривається можливість прогнозування ваг і зміщень, з урахуванням історичних даних, отриманих на основі попереднього навчання або схожих задач, а також з'являється нова спроможність організації більш ефективних обчислень.

5. Розроблено диференційні математичні моделі і методи прогнозування значень ваг елементів матриці, яка представляє всю сукупність зв'язків між нейронами кожного шару нейромережі, що реалізується шляхом спроможності представлення сукупності величини ваг, отриманих в процесі попереднього налаштування параметрів нейромережі, у вигляді часових рядів.

6. Для виявлення та оцінки ступеня взаємозв'язку між незалежними і залежними змінними, а також залежності елементів матриці ваг нейромережі, запропоновано диференційні математичні моделі кореляційного аналізу для виявлення найбільш значущих ознак, які негативно впливають на стабільність і інтерпретацію моделі штучного інтелекту, ідентифікація яких є основою покращення якості інтелектуальних моделей та суттєвого збільшення точності прогнозу.

## Література

1. Стратегія розвитку штучного інтелекту в Україні. За загальною редакцією А. І. Шевченка. Видавництво «Торпеда». Київ – 2023 р. С 306.
2. Стасюк О. І. Принципи відображення інноваційних моделей штучного інтелекту в інтелектуальних комп'ютерних мережах оптимізації функціонування енергетичних систем. Штучний інтелект. Національна академія наук України, Інститут проблем штучного інтелекту МОН України і НАН України. 2024, № 1, стр. 18-30.
3. Sopol, M., Stasyuk, O., Kuznetsov, V., Goncharova, L., Hubskeyi, P. Regina computer system for intelligent monitoring, diagnostics, and management of railway power supply systems *Diagnostyka*, 2021, 22(4), стр. 77–88 (Scopus) (Q3).

<https://www.ceeol.com/search/article-detail?id=1119979>

4. Stasiuk, A., Kuznetsov, V., Goncharova, L., Hubsnyi, P. Models of the computer intellectualization optimal strategy of the power supply fast-flowing technological processes of the railways traction substations. *Communications – Scientific Letters of the University of Zilina*, 2021, 23(2), C30–C36. (Scopus) (Q3).

<http://komunikacie.uniza.sk/index.php/communications/article/view/1680>

5. Stasiuk O.I., Goncharova L.L. *Mathematical Models and Methods for Analyzing Computer Control Networks of Railway Power Supply*. New Means Cybernetics, Informatics, Computers Engineering and Systems Analysis. Springer Science+Business Media New York 2018. Volume 54, Issue 1, February 2018, Pages 165-172. (Scopus) (Q3).

<https://link.springer.com/article/10.1007/s10559-018-0017-0>

6. Stasiuk A.I., Hryshchuk, R.V., Goncharova L.L. Mathematical differential models and methods for assessing the cybersecurity of computer networks intelligent control of technological processes of railway power supply. *New Means Cybernetics, Informatics, Computers Engineering and Systems Analysis*. Springer Science+Business Media New York 2018. Volume 54, Issue 4, February 2018, Pages 671-68. (Scopus) (Q3).

<https://link.springer.com/article/10.1007/s10559-018-0068-2>

7. Stasiuk A.I., Hryshchuk, R.V., Goncharova L.L. A Mathematical Cybersecurity Model of a Computer Network for the Control of Power Supply of Traction Substations. *Cybernetics and Systems Analysis*. Springer Science+Business Media New York Volume 53, Issue 3, May 2017, Pages 476-484.

<https://link.springer.com/article/10.1007/s10559-017-9949-z>

8. Stasyuk, A.I., Goncharova L.L., Mathematical models and methods of the analysis of computer networks of control of power supply of railways traction substations L.L. *Journal of Automation and Information Sciences*, 2017, 49(2), стр. 50–60.

<http://www.dl.begellhouse.com/journals/2b6239406278e43e,5bdc44c95254b2ed,779791cb12ca6912.html>

9. Alexander I. Stasiuk, Lidiya L. Goncharova Mathematical Models and Methods of Formation of Intelligent Computer Networks for Control of Power Supply and Optimization of Power Consumption of Railways. *Journal of Automation and Information Sciences*. Begell House Inc. (CIIA), New-York, Connecticut. Volume 50, 2018 Issue 8, pages 50-65. SCOPUS, Web of Science, ISI, INIS Atomindex ioport.net.

<http://www.dl.begellhouse.com/journals/2b6239406278e43e,2ec3cf2b062398ac,5e87262e3b8eefd4.htm>

10. Pukhov G.E., Taylor transformations and their application in electrical engineering and electronics [in Russian], Naukova dumka, Kiev, 1978.

## References

1. Stratehiia rozvytku shuchnoho intelektu v Ukraini. Za zahalnoiu redaktsiieiu A.I. Shevchenka. Vydavnytstvo «Torpeda». Kyiv – 2023 r. S 306.

2. Stasiuk O.I. The principles of displaying innovative models of artificial intelligence in intelligent computer networks for optimizing the functioning of energy systems. *Artificial Intelligence*. National Academy of Sciences of Ukraine, Institute of Artificial Intelligence Problems of the Ministry of Education and Science of Ukraine and the National Academy of Sciences of Ukraine. 2024, No. 1, pp. 18-30.

3. Sopel, M., Stasyuk, O., Kuznetsov, V., Goncharova, L., Hubsnyi, P. Regina computer system for intelligent monitoring, diagnostics, and management of railway power supply systems *Diagnostyka* 2021, 22(4), стр.77–88 (Scopus) (Q3).

<https://www.ceeol.com/search/articledetail?id=111999>

4. Stasiuk, A., Kuznetsov, V., Goncharova, L., Hubsnyi, P. Models of the computer intellectualization optimal strategy of the power supply fast-flowing technological processes of the railways traction substations. *Communications - Scientific Letters of the University of Zilina*, 2021, 23(2), стр. C30–C36. (Scopus) (Q3).

<http://komunikacie.uniza.sk/index.php/communications/article/view/1680>

5. Stasiuk O.I., Goncharova L.L. *Mathematical Models and Methods for Analyzing Computer Control Networks of Railway Power Supply*. New Means Cybernetics, Informatics, Computers Engineering and Systems Analysis. Springer Science+Business Media New York 2018. Volume 54, Issue 1, February 2018, Pages 165-172. (Scopus) (Q3).

<https://link.springer.com/article/10.1007/s10559-018-0017-0>

6. Stasiuk A.I., Hryshchuk, R.V., Goncharova L.L. Mathematical differential models and methods for assessing the cybersecurity of computer networks intelligent control of technological processes of railway power supply. *New Means Cybernetics, Informatics, Computers Engineering and Systems Analysis*. Springer Science+Business Media New York 2018. Volume 54, Issue 4, February 2018, Pages 671-68. (Scopus) (Q3)

<https://link.springer.com/article/10.1007/s10559-018-0068-2>

7. Stasiuk A.I., Hryshchuk, R. V., Goncharova L. L. A Mathematical Cybersecurity Model of a Computer Network for the Control of Power Supply of Traction Substations. *Cybernetics and Systems Analysis*. Springer Science+Business Media New York Volume 53, Issue 3, May 2017, Pages 476-484.

<https://link.springer.com/article/10.1007/s10559-017-9949-z>

8. Stasyuk, A.I., Goncharova L.L., Mathematical models and methods of the analysis of computer networks of control of power supply of railways traction substations L.L. *Journal of Automation and Information Sciences*, 2017, 49(2), стр. 50–60.

<https://www.dl.begellhouse.com/ru/journals/2b6239406278e43e,5bdc44c95254b2ed,779791cb12ca6912.html>

9. Alexander I. Stasiuk, Lidiya L. Goncharova  
Mathematical Models and Methods of  
Formation of Intelligent Computer Networks for  
Control of Power Supply and Optimization of Power  
Consumption of Railways. Journal of Automation and  
Information Sciences. Begell House Inc. (CIHA), New  
York, Connecticut. Volume 50, 2018 Issue 8, pages 50-  
65. SCOPUS, Web of Science, ISI, INIS Atomindex, io-  
port.net.  
<http://www.dl.begellhouse.com/journals/2b6239406278e43e,2ec3cf2b062398ac,5e87262e3b8eefd4.html>

10. Pukhov G.E., Taylor transformations and their  
application in electrical engineering and electronics [in  
Russian], Naukova dumka, Kiev, 1978.

The article has been sent to the editors 16.08.24.

After processing 14.08.24.

Submitted for printing 30.09.24.

Copyright under license CCBY-NC-ND