

ІВАНОТЧАК ОЛЕКСАНДР

Івано-Франківський національний технічний університет нафти і газу
<https://orcid.org/0009-0001-5806-5726>
e-mail: chaksw@gmail.com

КЕДЕНКО ІГОР

Івано-Франківський національний технічний університет нафти і газу
<https://orcid.org/0009-0006-9653-1739>
e-mail: kedenko123@gmail.com

КУЛІШ СЕРГІЙ

Івано-Франківський національний технічний університет нафти і газу
<https://orcid.org/0009-0004-7648-0116>
e-mail: serhii.kulich-a12322@nung.edu.ua

ГЛІБЧУК АНДРІЙ

Івано-Франківський національний технічний університет нафти і газу
<https://orcid.org/0009-0002-6307-0260>
e-mail: andrii.hlibchuk@gmail.com

ДМИТРЕНКО СЕРГІЙ

Івано-Франківський національний технічний університет нафти і газу
<https://orcid.org/0009-0009-7910-1923>
e-mail: sieergi0@gmail.com

КОНЦЕПТУАЛІЗАЦІЯ НЕЙРОМОДЕЛЕЙ ЗАДАЧ ПІДТРИМКИ ПРИЙНЯТТЯ РІШЕНЬ

Суть представлено дослідження полягає у всебічному аналізі штучних нейронних мереж (ШНМ) як інструментів для підтримки прийняття рішень та прогнозування, у порівнянні з традиційними моделями побудови статистично значимих оцінок та узагальнень, використання методів регресії на основі числових рядів даних клієнта. ШНМ пропонують альтернативний підхід до обчислень, який, на відміну від традиційного програмування, не вимагає повної алгоритмічної специфікації, а є базованим на методах індуктивного навчання, автоматичного адаптування, та узагальнень на основі знань та великих даних. Це робить їх особливо корисними для задач, де може бути важко формально визначити всі параметри завдання, такі як розмір, опис та важливість вхідних даних, очікувана кількість шарів та нейронів на кожному шарі, описи функцій активації, описи параметрів навчання, описи регуляризації, описи очікуваних втрат та оптимізацій, що має місце у прийнятті рішень в умовах невизначеності, де потрібно аналізувати великі обсяги неструктурованих даних клієнта. ШНМ забезпечують індуктивний метод для збору, зберігання та використання експертних знань, що є критично важливим для систем підтримки рішень. В роботі проведено огляд літератури та підсумовано, що ШНМ можуть бути порівняльно ефективними зі статистичними моделями у прогнозуванні та прийнятті рішень. Дослідження акцентує на потенційному внеску ШНМ у системи підтримки прийняття рішень та вказує на деякі обмеження, які можуть перешкодити отриманню високоточних результатів. Зазначається необхідність використання численних математичних засобів, які лежать в основі ШНМ, таких як теореми збіжності, теореми універсальної апроксимації, оптимізаційні алгоритми, аналіз властивостей – для визначення найкращих умов їх застосування в конкретних задачах прогнозування при побудові рекомендаційних систем та в системах підтримки прийняття рішень. Дослідження пропонує виважені оцінки щодо можливостей та обмежень ШНМ в контексті прикладних задач нафтогазової інженерії, в контексті вирішення проблем, пов'язаних із підтримкою прийняття експертних рішень та рекомендаційним прогнозуванням значень режимних та регламентних параметрів.

Ключові слова: інтелектуальні застосунки, прийняття рішень, системи підтримки рішень, штучні нейронні мережі, моделі прогнозування, рекомендаційні системи.

IVANOTCHAK OLEKSANDR, KEDENKO IHOR, KULISH SERHII, HLIBCHUK ANDRII, DMYTRENOK SERHII
Ivano-Frankivsk National Technical University of Oil and Gas

CONCEPTUALIZATION OF NEURAL MODELS FOR DECISION SUPPORT TASKS

This study delves into a comprehensive analysis of Artificial Neural Networks (ANNs) as tools for decision support and forecasting, juxtaposed with traditional models for statistically significant estimates and generalizations based on regression methods using client data series. Unlike conventional programming, ANNs offer a computing approach that does not require a complete algorithmic specification but is based on methods of inductive learning, automatic adaptation, and knowledge-based generalizations from big data. This makes them particularly useful for tasks where it might be difficult to formally define all the task parameters such as the size, description, and importance of input data, the expected number of layers and neurons per layer, activation functions, training parameters, regularization techniques, and expected losses and optimizations. These parameters are critical in decision-making under uncertainty, involving the analysis of large volumes of unstructured client data. ANNs employ an inductive method for collecting, storing, and utilizing expert knowledge, which is crucial for decision support systems. The literature review and summaries provided in this paper suggest that ANNs can be comparably effective to statistical models in forecasting and decision-making. The research highlights the potential contributions of ANNs to decision support systems and notes some limitations that could hinder achieving highly accurate results. It emphasizes the need to use numerous mathematical tools foundational to ANNs, such as convergence theorems, universal approximation theorems, optimization algorithms, and property analysis, to determine the best conditions for their application in specific forecasting tasks for recommendation systems and decision support systems. The study provides balanced assessments of the capabilities and limitations of ANNs in applied

contexts such as oil and gas engineering, and in addressing issues related to supporting expert decision-making and predictive forecasting of operational and regulatory parameters.

Keywords: Intelligent Applications, Decisions making, Decisions Support Systems, Artificial Neural Networks, Forecasting models.

Постановка задачі

Штучні нейронні мережі (ШНМ) широко застосовуються як засіб вирішення багатьох проблем у прогнозуванні та моделюванні рішень. Як показують практичні застосування вони можуть легко моделювати будь-який тип *параметричних або непараметричних процесів* і автоматично та оптимально трансформувати вхідні дані. Такі результати викликали значний інтерес до штучних нейронних мереж. Мета дослідження полягає в розробці та оптимізації штучної нейронної мережі (ШНМ) для моделювання специфічних завдань прийняття рішень в нафтогазовій інженерії, використовуючи інтенсивний процес набуття знань, видалення шумових змінних, вибір методу навчання мережі, а також налаштування архітектури мережі. Необхідно ідентифікувати релевантну інформацію в домені, яка потрібна для вирішення задачі, та визначити фактори рішень, які використовують експерти домену для вирішення типу проблеми, яка буде моделюватися за допомогою ШНМ, шляхом застосування методів інтерв'ю з експертами, аналізу існуючих даних, літературних оглядів. Далі треба виконати ідентифікацію та видалення несуттєвих змінних для підвищення точності моделі ШНМ для визначення високо корельованих змінних, застосування дискримінантного аналізу/факторного аналізу або ступінчастої регресії для видалення змінних, які не вносять вклад. Вибрати найбільш підходящий метод навчання на основі демографічних особливостей даних і задач прийняття рішень в даному класі. Реалізувати методи зворотного поширення помилок, додатково можливе використання радіально-базисної функції або контрпропагачії в залежності від характеристик даних (*наприклад каротажні криві*). Визначити очікуваний обсяг даних для навчання. Слідувати методології, для часових рядів, або використовувати правило, що кількість даних для навчання повинна бути в чотири рази більше числа вагових з'єднань для задач класифікації. Аналізувати складність та кількість унікальних кроків традиційного рішення експертів. Встановити кількість вузлів у останньому прихованому шарі рівною кількості факторів рішень, які використовують експерти домену для вирішення проблеми. Розробити здатну, ефективну та оптимізовану ШНМ для задачі підтримки прийняття рішень в домені нафтогазової інженерії. Максимально знизити вплив шумових даних та нерелевантних змінних на точність моделі. Підвищити розуміння ключових доменних факторів та їх впливу на процес прийняття рішень через аналітичне моделювання. Порівняти функціонал штучних нейронних мереж та класичних статистичних технік прогнозування часових рядів, прогнозування на основі регресії та моделі рішень на основі регресії.

Аналіз останніх джерел

Штучні нейронні мережі надають засоби для вирішення складних задач, орієнтованих на виявлення патернів, які включають категоризацію та аналіз часових рядів (*аналіз тенденцій та трендів*) [1–4]. Непараметричний характер нейронних мереж дозволяє розробляти моделі без попереднього знання про розподіл популяції даних або можливі взаємодії між змінними, що зазвичай вимагається у використовуваних найчастіше параметричних статистичних методах. Так, багатofакторна регресія вимагає, щоб похибка регресійного рівняння була нормально розподілена і також була гомоскедастичною. Інший статистичний метод, який часто використовується для категоризації, - це дискримінантний аналіз, але дискримінантний аналіз вимагає, щоб предикторні змінні мали багатовимірний нормальний розподіл. Оскільки такі припущення не застосовуються до моделей ШНМ, легкість розробки рішень для доменних проблем збільшується з використанням штучних нейронних мереж. Ще одним фактором, що сприяє успіху застосувань ШНМ, є їхня здатність створювати не тільки традиційні лінійні моделі, а й нелінійні, і тому рішення на базі штучних нейронних мереж можуть бути застосовані в ширшому діапазоні типів проблем – як лінійних, так і нелінійних.

Протягом останніх років було проведено значну кількість досліджень, спрямованих на покращення процесів *прийняття рішень* [5–9]. Ці дослідження призвели до численних розвитків у методах прогнозування базуючись на статистичних техніках та штучних нейронних мережах (ШНМ) в контексті задач прогнозування часових рядів, прогнозування на основі регресії та моделей прийняття рішень на основі регресії. ШНМ позиціонуються за їхню здатність вирішувати багато проблем прогнозування та моделювання рішень шляхом моделювання різних типів параметричних чи непараметричних процесів і автоматичного та оптимального трансформування вхідних даних. Тому необхідне порівняння штучних нейронних мереж та статистичних методів, та також порівняння з іншими моделями, такими як дискримінантний аналіз, що загалом і визначає контекст застосування штучних нейронних мереж в області задач прогнозування та прийняття рішень.

Штучні нейронні мережі є *математичними моделями* [10–13], по зразку організації та функціонування біологічних нейронів. Існує багато варіацій штучних нейронних мереж, які пов'язані з природою завдання, що ставиться перед мережею, а також численні варіації в моделюванні нейрону. У деяких випадках ці моделі тісно відповідають біологічним нейронам, а в інших випадках моделі значно відрізняються від біологічного функціонування. Література пропонує кілька потенційних переваг, які мають штучні нейронні мережі порівняно зі статистичними методами. Штучні нейронні мережі можуть бути універсальними апроксиматорами функцій навіть для нелінійних функцій. Вони також можуть оцінювати

функції за кусково-неперервними апроксимаціями. Той факт, що штучні нейронні мережі математично можна показати як універсальні апроксиматори функцій означає власне, що ШНМ можуть автоматично апроксимувати будь-яку функціональну форму, яка найкраще характеризує дані [14–17].

Хоча ця властивість мало цінна, якщо функціональна форма проста, наприклад, лінійна, вона тим не менше дозволяє ШНМ видобувати більше даних з складних основних функціональних форм. Також ШНМ можуть принаймні частково автоматично трансформувати вхідні дані. ШНМ також є інгерентно нелінійними. Це означає, що вони не тільки добре оцінюють нелінійні функції, але також можуть видобувати будь-які залишкові нелінійні елементи з даних після видалення лінійних термінів. Активно аргументуються переваги використання нелінійних моделей прогнозування. За допомогою одного або декількох прихованих шарів, ШНМ можуть автоматично розділяти вибіркового простір і побудувати різні функції в різних частинах цього простору. Це означає, що ШНМ мають здатність до побудови кусково-нелінійних моделей. Експерти вважають важливим можливість вибору методів екстраполяції, які ідентифікують і обробляють різкі зміни в історичних шаблонах даних, що свідчить на користь кускових моделей. Деякі статистичні методи часових рядів мають обмеження через спосіб, яким оцінюються моделі. Оцінка багатьох видів статистичних моделей часових рядів вимагає людської взаємодії і оцінки. Оцінка ШНМ, однак, може бути автоматизована. Також багато статистичних моделей повинні бути переоцінені періодично, коли надходять нові дані. Важливо, що багато алгоритмів ШНМ навчаються інкрементно.

Тим не менше, аналіз джерел показує також існування певних проблем з ШНМ [18–20]. По-перше, методологія та техніки моделювання ШНМ швидко змінюються, тоді як багато статистичних технік моделювання стабільні та добре розроблені. По-друге, програмне забезпечення для статистичних технік широко доступне, а програмне забезпечення для ШНМ комерційне, хоча і має гарну якість. По-третє, моделі ШНМ важче інтерпретувати та надати реальні значення змінним, ніж у випадку моделей прогнозування. По-четверте, ШНМ містять більше параметрів для оцінки, ніж більшість статистичних моделей прогнозування; це може призвести до проблем перенавчання. Також ШНМ вимагають більше часу на комп'ютерні розрахунки, ніж статистичні моделі.

Виклад основного матеріалу

Штучні нейронні мережі — це технологія, яка базується на дослідженнях мозку та нервової системи. Ці мережі імітують біологічну нейронну мережу, але використовують спрощений набір концепцій з біологічних нейронних систем. Зокрема, моделі ШНМ імітують електричну активність мозку та нервової системи. Елементи обробки (нейрод, нейрон або перцептрон) з'єднані з іншими елементами обробки. Зазвичай нейроди розташовані у шарі або векторі, при цьому вихід одного шару служить входом для наступного шару та можливо інших шарів. Нейрод може бути з'єднаний з усіма або підмножиною нейродів у наступному шарі, при цьому ці з'єднання імітують синаптичні з'єднання мозку. Вагові дані (weights), що входять в нейрод, імітують електричне збудження нервової клітини і, відповідно, передачу інформації всередині мережі або мозку. Вхідні значення до елемента обробки in_n множаться на вагу з'єднання $weight_{n,m}$ яка імітує зміцнення нейронних шляхів у мозку. Саме через регулювання сил з'єднань або ваг навчання імітується процес в ШНМ.

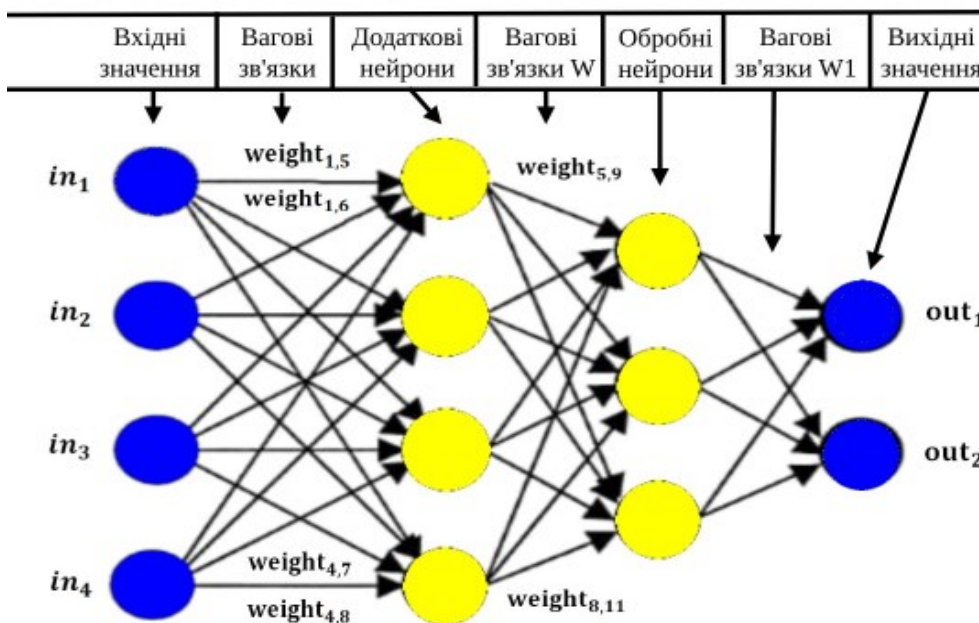


Рис. 1. Зразок типової архітектури штучної нейронної мережі

Усі вхідні значення з коригуванням ваги до елемента обробки потім агрегуються за допомогою функції вектор-скаляр, такої як сума тобто, $y = \sum weight_{ij} x_i$, середнє, максимальнє вхіднє значення або модальнє значення, щоб створити єдинє вхіднє значення для нейрода. Отримавши вхіднє значення, елемент обробки тоді використовує передавальну функцію для вироблення свого виходу відповідно до, вхідних сигналів для наступного шару обробки. Функція передачі перетворює вхіднє значення нейрода. Зазвичай це перетворення включає використання *сигмоїдальної*, *гіперболічної тангенсальної* або іншої *нелінійної* функції. Процес повторюється між шарами елементів обробки, поки нейронна мережа не виробить остаточнє вихіднє значення out_n , або відповідний *вектор значень*.

Теоретично, для імітації асинхронної активності людської нервової системи, елементи обробки штучної нейронної мережі також повинні активуватися з вагомим вхідним сигналом асинхронно. Більшість програмних і апаратних реалізацій штучних нейронних мереж, однак, впроваджують більш дискретизований підхід, який гарантує, що кожен елемент обробки активується один раз для кожної презентації вектора вхідних значень. Розвиток технології включав такі важливі етапи як : початкова ідея об'єднання кількох елементів обробки в мережу; визначення навчального правила для пояснення поведінки мереж нейронів; перший алгоритм навчання перцептрон; обчислювальні обмеження одношарових нейронних мереж ; алгоритм навчання зворотного поширення помилки, який дозволив навчати одночасно кілька шарів у мережі, що стало ключовим моментом у розвитку глибинних нейронних мереж; формування мереж здатних навчатися з прихованими шарами; ера MLP (multilayer perceptron's– багатшарові перцептрони); побудова алгоритму зворотного поширення. Процес побудови застосувань нейронних мереж було полегшено появою оболонок нейронних мереж, таких як Brainmaker, Neuralyst, Neuroshell, TensorFlow, PyTorch, Keras, Apache MXNet, Microsoft Cognitive Toolkit (CNTK) та доповнень до інструментів SAS, MATLAB та Excel, які надають розробникам засоби для визначення архітектури ШНМ та навчання нейронної мережі. Ці оболонки та інструментальні доповнення дозволяють розробникам ШНМ створювати рішення на базі ШНМ без необхідності глибокого розуміння теорії або термінології ШНМ.

Нейронні мережі можуть використовувати різні алгоритми навчання, які можна класифікувати на дві основні категорії на основі формату вхідних даних: бінарний вхід (тобто 0 і 1) або неперервний вхід. Ці категорії можна поділити на алгоритми з навчанням під наглядом і без нагляду. Алгоритми навчання під наглядом використовують різницю між бажаним і фактичним виходом для регулювання та остаточного визначення відповідних ваг для ШНМ. У одному з варіантів цього підходу деякі алгоритми навчання під наглядом інформують, чи правильний вихід для входу, і мережа регулює свої ваги з метою досягнення правильних результатів. Мережа Хопфілда (бінарна) і зворотнє поширення (неперервне) є прикладами алгоритмів навчання під наглядом. Алгоритми навчання без нагляду отримують лише вхідні стимули, і мережа організується з метою мати приховані елементи обробки, які реагують по-різному на кожний набір вхідних стимулів. Мережа не вимагає інформації про правильність виходу. ART I (бінарна) і Кохонен (неперервна) є прикладами алгоритмів навчання без нагляду.

Застосування нейронних мереж часто розглядають як "чорні скриньки", які визначають складні шаблони в даних. Однак, розробники ШНМ повинні проводити обширну інженерію знань і включати значну кількість знань з предметної області до штучних нейронних мереж, що проектуються відповідно. Успішна розробка штучних нейронних мереж вимагає глибокого розуміння етапів, залучених у проектування. Дизайн ШНМ вимагає від розробника прийняття багатьох рішень, таких як визначення входів, розміри навчальних і тестових даних, вибір алгоритму навчання, архітектура та топологія мережі, та вибір трансформаційної функції. Деякі з цих рішень залежать одне від одного. Наприклад, архітектура ШНМ та алгоритм навчання визначатимуть тип вхідного значення (тобто, бінарне чи неперервне). Тому важливо дотримуватися методології та добре визначеної послідовності кроків під час проектування ШНМ : визначення даних для використання; визначення вхідних змінних; розділення даних на навчальні та тестові набори; визначення архітектури мережі; вибір алгоритму навчання; трансформація змінних у вхідні дані мережі; навчання – повторюється до тих пір, поки вага помилки ШНМ не буде нижчою за прийнятне значення; тестування – на контрольній вибірці, для перевірки рівня загальності ШНМ .

Ранні дослідження штучних нейронних мереж є неоднозначними. В більш пізніх дослідженнях встановлено , що штучні нейронні мережі працюють так само добре, як і класичні статистичні моделі у прогнозуванні часових рядів (*time series*), і вони можуть фактично працювати краще за статистичні моделі для даних в окремих випадках. Випадок за моделями штучних нейронних мереж може бути підсилений іншими важливими атрибутами моделі, які важливі в конкретному застосуванні , як наприклад, здатність штучної нейронної мережі автоматизувати процес прогнозування. Зокрема метод "*М-змагань \ M-competitions*" полягає в зборі реальних часових рядів в формі систематичної вибірки з певної кількості серій із початкової бази даних. У початковому змаганні різні групи прогнозистів отримують всі дані, крім найновіших точок даних у кожному з рядів, і їм пропонується зробити прогнози для цих найновіших точок. Прогнози кожного учасника потім порівнюються з фактичними значеннями в наборі даних для перевірки. В даному випадку моделі штучних нейронних мереж працюють так само добре, як і автоматична процедура. Для часових рядів з довгою пам'яттю та часових рядів з короткою пам'яттю моделі штучних нейронних мереж дають порівнянні результати. Архітектура є ключовою в проектуванні успішної моделі прогнозування. В якості критерію порівняння виступає середня абсолютна відсоткова помилка мережі на

наборах симульованих часових рядів. Середнє значення для архітектур штучних нейронних мереж є кращим лише тоді коли в даних наявні тренди і шаблони. Зокрема штучні нейронні мережі часто працюють краще, коли робити прогнози понад перші кілька періодів. Як правило, порівняння моделей здійснюється за річними, квартальними і місячними даними з систематичної вибірки М-змагання часових рядів з використанням методів базованих на комбінуванні результатів моделей прогнозування, наївних моделей прогнозування, де прогноз наступного періоду є просто тим, що сталося в попередньому періоді, і методів заснованих на людських судженнях. Моделі також розробляються таким чином, щоб охопити випадки, які не могли бути прогнозовані. Крім того, доцільна стандартизація багатьох інших процедурних відмінностей як-от структура моделі штучних нейронних мереж. Усе це дає фундамент строгого порівняння статистичних методів і штучних нейронних мереж для випадку часових рядів і дозволяє ствердити, що штучні нейронні мережі дають кращі результати за статистичні методи та методи людського судження як на квартальних так і на місячних часових рядах. Перша архітектура прогнозувала всі періоди в горизонті прогнозування одночасно. Ця архітектура ШНМ працює приблизно так само добре, як і статистичні моделі. У другій архітектурі ШНМ прогноз для першого періоду горизонту прогнозування був згенерований попередньо. Його повертають назад у модель, щоб прогнозувати другий період горизонту прогнозування. Цей процес продовжується, поки не буде побудовано прогнозів для всього горизонту. Така архітектура ШНМ перевершує першу архітектуру відповідно. Метод бутстрепінгу (*bootstrapping*) у другій архітектурі є вирішальною відмінністю, оскільки бутстрепінг також покращує моделі прогнозування на основі суджень.

Таким чином, застосування штучних нейронних мереж є найбільш ефективними, коли присутні нелінійні шаблони, що пояснює сутність отриманих результатів. У першому випадку нелінійні шаблони могли виникнути через відносно більшу кількість нелінійностей у десезонованих квартальних і місячних серіях, в порівнянні з річними серіями. Такий результат також може бути пояснений, якщо в серії містилися нелінійності. Якщо так, то нелінійні штучні нейронні мережі повинні давати кращі прогнози, ніж лінійні моделі; покращення стають більш помітними, коли горизонт прогнозування збільшується.

Моделі регресії широко використовуються для прогнозування та моделювання процесів прийняття рішень, зокрема в контексті забезпечення процедур підтримки процесу прийняття рішень. Доцільним є порівняння штучних нейронних мереж і моделей регресії, незалежних від завдань, які підлягають моделюванню та порівняльне дослідження штучних нейронних мереж та моделей регресії при використанні для моделювання процесу прийняття рішень; порівняння штучних нейронних мереж та регресії з використанням реальних багатовимірних даних для прогнозування. Як правило генерують дані, що представляють поширені біваріативні функціональні форми, використовувани в прогнозуванні: лінійні, нелінійні, квадратні і тп. Для кожної функціональної форми створюються набори точок з відповідними рівнями шуму. Штучні нейронні мережі оцінюються для кожного з вищезазначених наборів даних. Відповідність штучних нейронних мереж порівнюється з відповідністю справжніх функціональних форм з використанням наборів даних для перевірки, що складаються з заданої кількості точок кожна. Відповідність штучних нейронних мереж до реальних даних нафтогазової інженерії є такою ж, як відповідність справжніх функціональних форм. Також, для всіх практичних цілей, штучні нейронні мережі відповідають даним так само добре, як і правильно вказана модель регресії з відповідним перетворенням незалежних змінних (наприклад в формі режимних параметрів процесу буріння нафтогазових свердловин). У цьому дослідженні, штучні нейронні мережі показали порівняно добрі результати навіть при високому рівні шуму та малих розмірах вибірки, розширивши дослідження на рівні симуляції та генерації штучних функціональних форм. Результати узагальнювалися на інші функціональні форми, включаючи поліноми другого порядку, форми з кількома незалежними змінними, рівняння експоненційного зростання та логістичні моделі. В усіх цих випадках, штучні нейронні мережі знову були в межах відповідності для справжньої функціональної форми з відповідними перетвореннями незалежних змінних. Також було визначено, що штучні нейронні мережі так само вразливі до викидів, як і регресія, що є важливим фактором порівняння ефективності штучних нейронних мереж та регресії загалом. Таке порівняння також показує, що штучні нейронні мережі ефективні в оцінці справжніх функціональних форм; їх середнє значення відповідно менше від значень для релевантної функціональної форми. Ця здатність добре працює, коли функціональна форма невідома, що робить штучні нейронні мережі привабливим вибором для обробки даних в нафтогазовій інженерії, де дані мають виражено нелінійні залежності та низьку структуру зацілю.

Модель прийняття рішень намагається передбачити людський вибір на основі факторів, які людина використовує для прийняття рішень. Зазвичай ці моделі мають лінійну функціональну форму, і для їх оцінки використовується регресійний аналіз. Оцінка моделей штучних нейронних мереж і регресійних моделей дозволяє стверджувати, що модель штучної нейронної мережі перевершує модель регресії з випадковими ефектами, але не з фіксованими ефектами для поточного рішення. Нафтогазову інженерію цікавлять рішення щодо планування виробництва, моделювання за допомогою штучних нейронних мереж та регресійних правил прийняття рішень. Штучні нейронні мережі можуть краще передбачати випадково вибрані дані у вибірці для перевірки. Штучна нейронна мережа ідентифікує структуру моделі краще, ніж регресійна модель. Проте емпірично оцінені моделі показують однаково добрі результати, а структура моделі отримується така сама, що й у порівнянних регресійних моделях. Моделі штучних нейронних мереж, в свою чергу, показали такі ж результати, але не кращі, ніж моделі, що використовували лінійну регресію. Обидві моделі, тим не менше, перевершили фактичних приймальників рішень в симуляції на основі

історичних даних. Агрегування даних від усіх приймачів рішень для оцінки композитної моделі штучної нейронної мережі дозволяє оцінити отриману модель штучної нейронної мережі, яка даватиме кращі результати, ніж статистичні моделі. Продуктивність композитної штучної нейронної мережі не відрізнятиметься значно від продуктивності статистичних композитних моделей при проміжних рівнях змінності навколишнього середовища; однак при низьких рівнях варіативності статистична композитна модель показує все таке кращі результати. Загалом, в ряді випадків, штучні нейронні мережі можуть показувати такі ж результати, як і регресія, у моделюванні прийняття рішень. Однак моделі штучних нейронних мереж можуть бути особливо корисними, якщо рішення містить важливі *нелінійні елементи* або деякі інші переваги штучних нейронних мереж, що будуть вирішальними факторами в даному застосуванні, наприклад, здатність штучної нейронної мережі автоматизувати складні процеси без наявності лінійних алгоритмів.

Існує чимало реалізацій, у яких моделі за винятком звичайного методу найменших квадратів і часових рядів порівнювали з штучними нейронними мережами у загальноприйнятих бізнес-завданнях. Наприклад, логістична регресія часто використовується у класифікаційних задачах, де змінна відгуку має бінарне значення. Порівнювали мережі зворотного поширення помилок з моделями логістичної регресії у прогнозуванні певних типів даних. Модель штучної нейронної мережі показала хороші результати у прогнозуванні і була кращим прогнозистом, ніж логістична модель. Використовували моделі штучних нейронних мереж та логістичної регресії для прогнозування рейтингів та ризиків. Моделі штучних нейронних мереж мали нижчу середню абсолютну помилку у своїх прогнозах і були чутливішими до змін у показниках ризику, ніж їхні логістичні аналоги.

Штучні нейронні мережі є альтернативою дискримінантному аналізу. Практичні проблеми, де було застосовано порівняння між штучними нейронними мережами та дискримінантним аналізом, включають, як правило прогнозування ряду показників. В таких застосуваннях, модель штучної нейронної мережі перевершує дискримінантний аналіз. В даному випадку, кількість наборів даних як правило обмежена, а набори даних — малі. Ретельної оцінки заслуговують ряд моделей, включаючи штучні нейронні мережі, дискримінантний аналіз, логістична регресія. Задача полягає в їх ретельному тестуванні на вибірках даних для перевірки. Штучні нейронні мережі в даному випадку мають кращу прогностичну точність, ніж інші моделі. Такий результат можна узагальнити, враховуючи унікальність модельованої проблеми.

Розглянемо наступну проблему. ПАТ Укрнафта компанія з повним циклом виробництва нафтопродуктів: від розвідки до видобутку та переробки до стандартних видів палива. Компанія, планує рекламувати новий нафтопродукт за допомогою дорогого рекламного набору. Для зниження витрат і максимізації вигоди компанія прагне звернутися лише до тих клієнтів, які, ймовірно, куплять новий нафтопродукт. Строго кажучи, компанія бажає поділити свою базу клієнтів на дві категорії: «цільові» (*targ*) та «нецільові» (*non targ*). Це, звичайно, є типовою класифікаційною проблемою: мета полягає в тому, щоб розподілити n -вимірні сутності (клієнтів) на m класів, де $m = 2$. Виходитимемо з припущення, що на вході маємо *файл клієнтів і файл транзакцій*. Перший файл відстежує n атрибутів клієнта, позначених як $Attr_1, \dots, Attr_n$ (ідентифікаційні дані клієнта, номенклатура закупок і т.п.). Згідно такої нотації, множина всіх можливих клієнтів буде декартовим добутком

$$X = Attr_1 \times \dots \times Attr_n$$

, а конкретний клієнт позначається як

$$x = \langle attr_1, \dots, attr_n \rangle \in X$$

а файл клієнтів компанії позначається як

$$X^{file} \in X$$

Файл транзакцій вказує, який клієнт купив який продукт і коли. Також припускаємо, що існує певна метрика або експерт у галузі, який може розділити продукти компанії на дві групи: продукти, які є пов'язаними з рекламованим продуктом, та продукти, які є непов'язаними з новинками ринку від продуктів компанії.

Виходячи з цих припущень, файли компанії можуть бути перероблені для генерації двох наборів даних (*dataset*), таким чином:

$$X^{rel} = \{x | x \in X^{file}\}, \text{ випадок покупки пов'язаних продуктів,}$$

$$X^{unrel} = \{x | x \in X^{file} \setminus X^{rel}\}, \text{ випадок покупки не пов'язаних продуктів.}$$

Перший набір містить приклади клієнтів, які можуть зацікавитися рекламованим продуктом, тоді як другий набір містить всіх інших клієнтів. Щоб завершити постановку проблеми, припустимо зараз, що компанія має доступ до списку клієнтів, позначеного як $X^{list} \subset X$, який складається з потенційних приймачів продукту, чия поведінка щодо купівлі невідома. Суть задачі полягає в тому, чи можемо ми використовуючи такі набори даних та *нейронну мережу* виконати прогнозування, які клієнти, ймовірно, придбають новий продукт, що виводиться на ринок.

Розглянемо випадок простої мережі, яка складається з n вхідних одиниць та однієї обробної одиниці.

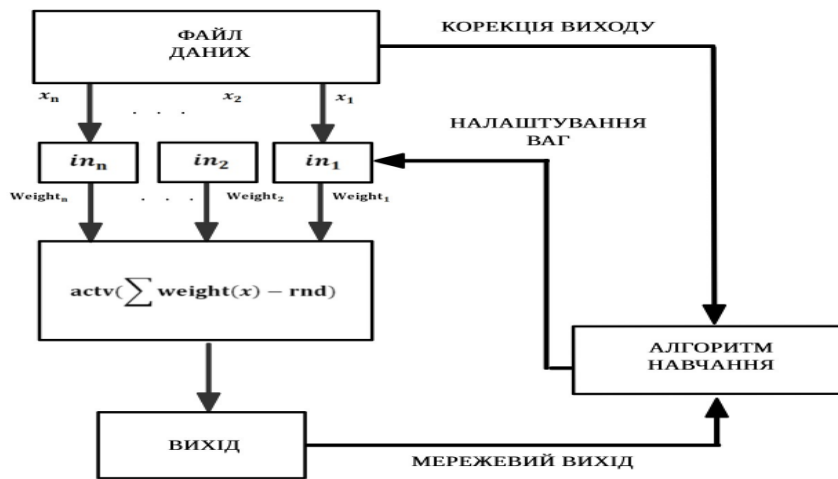


Рис. 2. Абстрагована структура нейрона

Вхідні одиниці з'єднані з обробною одиницею за допомогою n з'єднань, ширина яких представлена набором числових ваг, позначених як W_1, \dots, W_n :

$$Weights :: w_1, \dots, w_n$$

Вхідні одиниці зберігають значення опису атрибутів клієнтів, позначені як $[x_1, \dots, x_n] \rightarrow [x.attr :: x_1.attr_1, \dots, x_n.attr_n]$

Обробна одиниця характеризується двома математичними операціями: фіксованим оператором зваженої суми, який обчислює скалярний добуток

$$weight(x) = \sum_i^n weight_i(x_i)$$

та фіксованою активаційною функцією

$$actv(): weight(x) \rightarrow [-1; 1]$$

Якщо мережа вважає, що клієнт у питанні має бути класифікований як цільовий, вона виведе 1. В іншому випадку вона виведе -1.

Навчальні дані складаються з наборів X^{rel} і X^{Unrel} , члени яких відомі як цільові та нецільові відповідно. Фаза навчання — циклічний процес, в якому вчитель, що насправді є комп'ютерною програмою повторно вибирає об'єкти і передає їх у мережу для класифікації. Після порівняння відповіді мережі з правильною класифікацією, процедура мінімізації помилок коригує ваги мережі у спробі виправити неправильні рішення класифікації. Далі мережі подається інший об'єкт, і процес продовжується.

Описавши основні блоки побудови мереж прямого поширення і алгоритмів навчання, слід перейти до дослідження їх потенційного використання та обмежень у підтримці процесі прийняття рішень. Рамки *СППР\DSS* були розроблені з однією метою: допомогти дослідникам та практикам систематично мислити про численні фактори, які відіграють роль у проектуванні та використанні систем підтримки прийняття рішень. Такі рамки організовані навколо трьох складових: середовище, компоненти та ресурси. Основне припущення полягає в тому, що за ідеальних умов, зовнішні характеристики середовища системи мають відображатися в її внутрішніх компонентах, які, в свою чергу, визначають відповідні ресурси, необхідні для реалізації системи. На практиці зв'язок часто відбувається у зворотному порядку: ресурси, які фактично використовуються, визначають архітектуру системи, яка, в свою чергу, визначає здатність системи впливати на призначене середовище. Отже, слід відповідно досліджувати середовище, компоненти та ресурси, які або підсилюють, або перешкоджають використанню *нейронних мереж* у додатках підтримки прийняття рішень.

Процеси прийняття рішень рідко мають місце в ідеальних умовах; тому характеристики середовища системи мають бути враховані проектувальниками таких систем. Під середовищем в даному випадку розуміють низку зовнішніх факторів, які мають значення для роботи системи, але не під контролем проектувальника системи. Таке середовище доцільно поділити на дві основні категорії: характеристики завдань та шаблон доступу. Характеристика завдання, яка найбільш критично впливає на підтримку прийняття рішень, — це структуруваність, тобто ступінь, до якого приймач рішень може застосувати єдину попередньо визначену модель до базової проблеми. Друга характеристика — це керівний рівень, на якому система має втручатися в процес прийняття рішень. Третя характеристика — це когнітивна фаза, яку система призначена підтримувати. Нарешті, четверта характеристика — це функціональна область підтримуваного додатку. Непотрібно наголошувати, що різні проблеми прийняття рішень значно відрізняються за своєю структурованістю, керівним рівнем, фазою та функціональною областю. Кожна з цих варіацій передбачає різний набір обмежень і рекомендацій щодо дизайну типу підтримки прийняття рішень, яка потрібна. Багаточисельні приклади реалізації показали, що мережі прямого виведення особливо добре класифікують нечіткі об'єкти в конкретні категорії. Як виявилось, багато важливих бізнес-проблем можуть бути представлені у вигляді побудови та імплементації класифікацій шляхом переведення множин об'єктів в різні виділені категорії, які потім потребують відповідно різного поводження від приймача рішень.

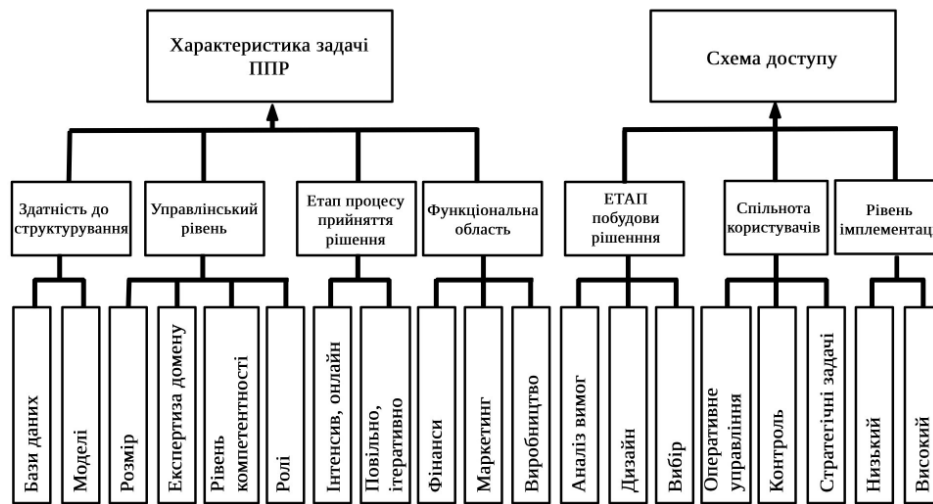


Рис. 3. Структура середовища підтримки прийняття рішень

Таким чином, узагальнена, загальна структура проблем, які підходять для мереж прямого виведення, полягає у побудові відображення, $d.rule :: [X \rightarrow C]$, де X є декартовим добутком $X = \langle X_1 \times \dots \times X_n \rangle$ атрибутів об'єкта, тоді як $C = \{c_1, \dots, c_n\}$ представляє набір класів обмежень відповідно. Правило рішення $d.rule$ представляє тип відображення, яке співвідносить вектори в X до класів у C . Загалом, кожне правило, може бути наближено дедуктивно, якщо існує певне явне знання про обґрунтування класифікації, або індуктивно, якщо існує відповідний релевантний зразок $\langle x, d.rule(x) \rangle | x \in X$ об'єктів представлення та їхніх класифікацій.

Основна складність полягає в неструктурованості завдання прийняття рішень, що може виникнути у цьому контексті з трьох причин. По-перше, може бути складно визначити релевантний набір атрибутів, оскільки описи об'єктів можуть бути надмірними, корелювати або взагалі бути невимірюваними. По-друге, набір цільових класів може бути частково невідомим, як у випадку з відображенням нових продуктів у набір стандартних категорій, який потрібно періодично оновлювати. Нарешті, і, можливо, найкритичніше, правило рішення $d.rule$ може заперечувати спрощені інтерпретації. У таких випадках традиційні моделі, такі як, наприклад, правила лінійної дискретизації та байесові класифікатори, не зможуть надати шукане наближення.

Загалом, статистичні класифікатори, так само як і класифікатори на базі правил, як, наприклад, має місце в діагностичних експертних та рекомендаційних системах, роблять сильні припущення щодо структури $X, C, d.rule$. Наприклад, моделі лінійної дискретизації вимагають, щоб атрибути – пояснювальні змінні x_1, \dots, x_n були незалежними; навчальні набори $\langle x, d.rule(x) \rangle$ були взяті з популяції, що мають багатовимірні нормальні розподіли та ідентичні матриці коваріацій; простір об'єктів має бути лінійно розділним. Моделі для імплементації правил висновку з невпевненостями теж представляє інтерес для дослідження. Наприклад, експертні системи здаються менш обмежувальними, хоча аналіз їхніх базових механізмів генерації впевненостей показує, що вони також роблять сильні (хоча й неявні) припущення про незалежність атрибутів. Крім того, системи на основі правил (*rules based systems*) вимагають принаймні часткового визначення правил, у більшості випадків – бази правил (*rules base*), отриманої від експерта-людини в домені активації.

На противагу цьому, нейронні мережі не мають робити жодних апіорних припущень щодо структури правил. Для побудови нейронного рішення проблеми класифікації

$$d.rule :: X_1, \dots, X_n \rightarrow \{c_1, \dots, c_n\}$$

будується мережа, в якій деякі одиниці представляють n вхідних значень, деякі одиниці представляють m класів, а решта одиниць реалізують правило рішення $d.rule$. Основна ідея тут полягає в тому, що кожне правило не потрібно явно визначати; замість цього, нейронна реалізація буде автоматично еволюціонувати: оскільки мережа бачить все більше і більше прикладів $\langle x_1, \dots, x_n \rangle$ та їхніх правильних класифікацій $d.rule \langle x_1, \dots, x_n \rangle$ вона коригує визначення правила в напрямку, який мінімізує її власні помилки класифікації.

Отже, порівняно з традиційними класифікаторами, які широко використовуються у підтримці прийняття рішень, нейронні мережі відзначаються мінімальними вимогами щодо структури проблеми. Це робить нейронні мережі особливо придатними для підтримки складних проблем класифікації, у яких обґрунтування відображення є нечітким, непослідовним або повністю невідомим. Таким чином, мережі прямого виведення представляють змішаний випадок щодо структурованості: з одного боку, вони вимагають, щоб базова проблема була сформульована у формі

$$d.rule :: [X \rightarrow C]$$

З іншого боку, як тільки ця мінімальна структурна вимога задоволена, самі проблеми можуть бути досить неструктурованими, оскільки апріорне знання про правила не є необхідним.

Висновки

Представлене дослідження обґрунтовує, що, штучні нейронні мережі є універсальними апроксиматорами функцій та дозволяють ідентифікувати характеристики проблеми такі як форма функції та розмір вибірки, які дозволяють передбачити, коли штучні нейронні мережі будуть прогнозувати краще, ніж статистичні моделі. Однією з фундаментальних властивостей ШНМ є їхня здатність діяти як універсальні апроксиматори. Це означає, що ШНМ можуть апроксимувати будь-яку неперервну функцію з будь-якої скінченної вимірності до заданої ступеня точності, за умови що мережа має достатньо велику кількість нейронів. Ця теоретична властивість вказує на високий потенціал ШНМ у моделюванні складних нелінійних зв'язків, які можуть не бути доступними для традиційних статистичних методів. ШНМ можуть ефективно ідентифікувати та адаптуватися до різних форм функцій, що входять у моделі даних. Це включає складні поліноміальні залежності, ірраціональні та трансцендентні функції, які часто зустрічаються в реальних даних. Розуміння форми функції дозволяє ШНМ точно налаштувати свої ваги та структуру для оптимального навчання і прогнозування. Розмір вибірки також впливає на ефективність ШНМ. З більшими датасетами ШНМ можуть "вивчити" більше варіативності в даних, що покращує їх здатність до узагальнення на нових, невидимих раніше даних. Ідентифікація оптимального розміру вибірки допомагає забезпечити, що мережа не перенавчиться на занадто малій кількості даних або не втратить здатність до адаптації на занадто великій кількості даних. Інтегруючи знання про форму функції та оптимальний розмір вибірки, ШНМ можуть визначити сценарії, в яких вони ймовірно перевершать статистичні моделі. Зокрема, в умовах високої нелінійності та складності зв'язків між змінними, ШНМ можуть надати більш точне та надійне прогнозування завдяки їх здатності апроксимувати складні моделі без жорсткого припущення про форму зв'язку. Так само, слід відзначити здатність штучних нейронних мереж хоча б частково автоматично трансформувати вхідні змінні. Здатність ШНМ до часткової автоматичної трансформації вхідних змінних забезпечує їх велику адаптивність та ефективність у широкому спектрі прикладних задач. Ця здатність є однією з основних причин, чому ШНМ вважаються одними з найпотужніших інструментів в сучасному машинному навчанні і штучному інтелекті, особливо у випадках, коли потрібно обробляти великі обсяги складних і нелінійно пов'язаних даних. Ця здатність є однією з ключових переваг ШНМ порівняно з багатьма традиційними моделями машинного навчання, які часто вимагають ретельної підготовки та інженерії функцій. ШНМ можуть автоматично виконувати трансформацію вхідних даних через їх здатність виявляти та адаптуватися до складних і часто нелінійних залежностей у вхідних даних. Внутрішні (приховані) шари мережі можуть автоматично виробляти високорівневі абстракції вхідних змінних, ефективно перетворюючи сирові дані у форму, що краще підходить для задачі, яка розв'язується. Нелінійність введена через функції активації (наприклад, ReLU або сигмоїд) дозволяє мережі формувати комплексні патерни, які можуть відображати складні залежності між вхідними та вихідними змінними. Зворотне поширення помилки – метод оптимізації, що дозволяє мережі "навчатися" від помилок, що робить процес адаптації до вхідних даних динамічним і цілеспрямованим.

Таким чином, представлене дослідження вказує на універсальність штучних нейронних мереж (ШНМ) як апроксиматорів функцій, що може глибоко трансформувати підходи до *підтримки прийняття рішень*. Важливість ШНМ у таких задачах зумовлена їх здатністю ідентифікувати і адаптувати складні, часто нелінійні *взаємозв'язки в даних*, які традиційні статистичні методи можуть пропустити.

Література

1. Han, Y., Huang, G., Song, S., Yang, L., Wang, H., & Wang, Y. (2021). Dynamic neural networks: A survey. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 44(11), 7436-7456.
2. Szandała, T. (2021). Review and comparison of commonly used activation functions for deep neural networks. *Bio-inspired neurocomputing*, 203-224.
3. Jäger, G. (2019). Replacing rules by neural networks a framework for agent-based modelling. *Big Data and Cognitive Computing*, 3(4), 51.
4. Wang, D. B., Feng, L., & Zhang, M. L. (2021). Rethinking calibration of deep neural networks: Do not be afraid of overconfidence. *Advances in Neural Information Processing Systems*, 34, 11809-11820.
5. Rizk, Y., Awad, M., & Tunstel, E. W. (2018). Decision making in multiagent systems: A survey. *IEEE Transactions on Cognitive and Developmental Systems*, 10(3), 514-529.
6. Jia, S., Lin, P., Li, Z., Zhang, J., & Liu, S. (2020). Visualizing surrogate decision trees of convolutional neural networks. *Journal of Visualization*, 23, 141-156.
7. O'Connell, R. G., Shadlen, M. N., Wong-Lin, K., & Kelly, S. P. (2018). Bridging neural and computational viewpoints on perceptual decision-making. *Trends in neurosciences*, 41(11), 838-852.
8. Duan, Y., Edwards, J. S., & Dwivedi, Y. K. (2019). Artificial intelligence for decision making in the era of Big Data—evolution, challenges and research agenda. *International journal of information management*, 48, 63-71.
9. Humbird, K. D., Peterson, J. L., & McClarren, R. G. (2018). Deep neural network initialization with decision trees. *IEEE transactions on neural networks and learning systems*, 30(5), 1286-1295.

10. Chen, Y., Shi, Y., & Zhang, B. (2018). Optimal control via neural networks: A convex approach. *arXiv preprint arXiv:1805.11835*.
11. Iyer, R., Li, Y., Li, H., Lewis, M., Sundar, R., & Sycara, K. (2018, December). Transparency and explanation in deep reinforcement learning neural networks. In *Proceedings of the 2018 AAAI/ACM Conference on AI, Ethics, and Society* (pp. 144-150).
12. Agarwal, R., Melnick, L., Frosst, N., Zhang, X., Lengerich, B., Caruana, R., & Hinton, G. E. (2021). Neural additive models: Interpretable machine learning with neural nets. *Advances in neural information processing systems*, 34, 4699-4711.
13. Angelov, P., & Soares, E. (2020). Towards explainable deep neural networks (xDNN). *Neural Networks*, 130, 185-194.
14. Zaki, H. (2024). *Unleashing the Power of Neural Networks in Big Data Analytics: Harnessing Insights from Data-Driven Approaches* (No. 12482). EasyChair.
15. Emmanuel, O., Misra, S., & Koyuncu, M. (2020). A deep neural network-based advisory framework for attainment of sustainable development goals 1-6. *Sustainability*, 12(24), 10524.
16. Dong, H., Mao, J., Lin, T., Wang, C., Li, L., & Zhou, D. (2019). Neural logic machines. *arXiv preprint arXiv:1904.11694*.
17. Zohuri, B., & Moghaddam, M. (2018). Neural network driven supper artificial intelligence based on internet of things and big data. *SF J Artificial Intel*, 1(1), 2.
18. Sánchez-Sánchez, C., & Izzo, D. (2018). Real-time optimal control via deep neural networks: study on landing problems. *Journal of Guidance, Control, and Dynamics*, 41(5), 1122-1135.
19. Gawlikowski, J., Tassi, C. R. N., Ali, M., Lee, J., Humt, M., Feng, J., ... & Zhu, X. X. (2023). A survey of uncertainty in deep neural networks. *Artificial Intelligence Review*, 56(Suppl 1), 1513-1589.
20. Liu, T., Wen, W., Jiang, L., Wang, Y., Yang, C., & Quan, G. (2019, June). A fault-tolerant neural network architecture. In *Proceedings of the 56th Annual Design Automation Conference 2019* (pp. 1-6).