

ПРОЦЮК ВОЛОДИМИР

Івано-Франківський національний  
технічний університет нафти і газу  
<https://orcid.org/0000-0003-0055-2780>  
e-mail: [v.v.protsiuk@gmail.com](mailto:v.v.protsiuk@gmail.com)

## ПОБУДОВА ІНТЕЛЕКТУАЛЬНОЇ СИСТЕМИ НА ОСНОВІ ПРАВИЛ З ФУНКЦІЯМИ ГЛИБОКОГО НАВЧАННЯ ДЛЯ ПРОБЛЕМ БУРІННЯ НАФТОГАЗОВИХ СВЕРДЛОВИН

Стаття присвячена вирішенню проблем прогнозного моделювання за допомогою методів машинного навчання в умовах невизначеності у величезних масивах даних, створених у різних секторах економіки, зокрема нафтогазовій промисловості, через поширення IoT і хмарних сервісів. Автор зазначає, що існуючі методи машинного навчання, включаючи широко використовувані методи глибокого навчання, стикаються з обмеженнями в досягненні високої точності прогнозування через різні невизначеності. У статті досліджуються підходи до нечіткого навчання для подолання таких невизначеностей, як неточність і неоднозначність, але підкреслюються їх обмеження щодо неповноти та нечіткості. Стверджується, що експертні системи на основі правил, доповнені глибоким навчанням, пропонують більш надійну основу для вирішення таких невизначеностей шляхом інтеграції асоціативної пам'яті, допомагаючи в отриманні більш точних прогнозних моделей, особливо в сценаріях з великими обсягами даних, як процеси буріння нафти і газу. Дослідження зосереджено на вдосконаленні прогнозного моделювання в умовах невизначеності у великих масивах даних. Обговорюються обмеження нечіткого навчання при обробці неповних даних і пропонується гібридний підхід до проблеми. Інтеграція методу навчання на основі асоціативної пам'яті в процедури логічного висновку дозволяє виявляти точні моделі даних, тим самим покращуючи якість прогнозування в умовах невизначеності. Цей комплексний підхід має на меті підвищити точність прогнозування шляхом використання сильних сторін глибокого навчання в розпізнаванні образів і здатності систем на основі правил справлятися з невизначеністю. Головним результатом наукової роботи є розробка нового методу, який інтегрує рівень глибокої обробки з асоціативною пам'яттю в систему на основі правил для підвищення точності прогнозування в умовах невизначеності. Це було досягнуто за рахунок використання багатошарової нейронної мережі та додавання додаткових параметрів. Цей метод значно підвищив точність прогнозування динаміки експлуатаційних параметрів у процесі буріння. Таким чином, представлене дослідження є новим внеском у завдання розробки методів прогнозування в умовах невизначеності, що особливо актуально при бурінні нафти та газу.

**Ключові слова:** автоматизація процесу буріння, системи підтримки прийняття рішень на основі знань, експертні системи, багатошарові нейронні мережі, невизначеність, нечіткість, методи прогнозування, глибинне машинне навчання.

PROTSIUK VOLODYMYR  
Ivano-Frankivsk National Technical University of Oil and Gas

## THE CONSTRUCTION OF INTELLIGENT RULE-BASED SYSTEM WITH DEEP-LEARNING FUNCTIONALITY FOR OIL AND GAS WELLS DRILLING

The article is devoted to solving the problems of predictive modeling using machine learning methods under conditions of uncertainty in huge data sets created in various sectors of the economy, in particular, the oil and gas industry, due to the spread of IoT and cloud services. The author notes that existing machine learning methods, including widely used deep learning methods, face limitations in achieving high prediction accuracy due to various uncertainties. The article explores fuzzy learning approaches to overcome uncertainties such as imprecision and ambiguity, but emphasizes their limitations of incompleteness and vagueness. It is argued that rule-based expert systems augmented with deep learning offer a more robust framework for dealing with such uncertainties by integrating associative memory, helping to produce more accurate predictive models, especially in data-intensive scenarios such as oil and gas drilling processes. The study focuses on improving predictive modeling under conditions of uncertainty in large data sets. We discuss the limitations of fuzzy learning when processing incomplete data and propose a hybrid approach to the problem. Integration of the associative memory learning method into the logical inference procedures allows to identify accurate data models, thereby improving the quality of forecasting under uncertainty. This integrated approach aims to improve forecasting accuracy by leveraging the strengths of deep learning in pattern recognition and the ability of rule-based systems to cope with uncertainty. The main result of the research work is the development of a new method that integrates a level of deep processing with associative memory into a rule-based system to improve forecasting accuracy under uncertainty. This was achieved by using a multilayer neural network and adding additional parameters. This method significantly improved the accuracy of predicting the dynamics of operational parameters during drilling. Thus, the presented study is a new contribution to the task of developing forecasting methods under conditions of uncertainty, which is especially relevant for oil and gas drilling.

**Keywords:** drilling process automation, knowledge-based decision support systems, expert systems, multilayer neural networks, uncertainty, fuzziness, forecasting methods, deep machine learning

### Постановка проблеми

Точне прогнозування з використанням реальних даних вважається складним завданням для різних методів машинного навчання. Відмічається, що на сьогодні в різних наукових і промислових галузях по всьому світу безперервно генерується велика кількість даних завдяки Інтернету речей (IoT) і хмарним сервісам. Ці великі обсяги даних неминуче містять різні невизначеності, такі як: неповнота, незнання, розпливчастість, неточність і неоднозначність. Ці невизначеності становлять значну проблему для точного прогнозування на основі даних. Для подолання згаданих вище невизначеностей широко використовуються

підходи нечіткого навчання [1, 2]. Ці підходи використовуються в обробці зображень, управлінні портфоліо, управлінні двигунами, де невизначеність є регулярним явищем. Системи нечіткого навчання автоматично вивчають нечіткі функції належності і, відповідно, виводять нечіткі правила з великої кількості навчальних даних [3, 4]. Використовуючи механізм виведення, нечіткі значення генеруються з нечітких правил. Потім нечіткі значення перетворюються на чіткі за допомогою різних методів дефазифікації, таких як метод центру ваги, метод середнього максимуму та метод середнього значення по центру. Однак системи нечіткого навчання можуть вирішувати проблеми невизначеності, пов'язані з неточністю, неоднозначністю та розмитістю, але не з неповнотою та незнанням.

Експертні системи, засновані на правилах (Rule-Based Expert Systems) [5, 6], являють собою вдосконалену версію систем нечіткого навчання. Вони сприяють кращому представленню невизначених знань завдяки включенню структури переконань. Зазвичай, експертна система складається з двох основних компонентів: бази знань та механізму виведення. У традиційній базі знань в якості схеми представлення знань використовуються правила "ЯКЩО-ТО" (IF-THEN), наприклад, "ЯКЩО умова 1, ТО висновок 1". Семантика цього правила полягає в тому, що "висновок 1" є на 100% визначеним, оскільки "умова 1" є правдивою. Однак це правило не охоплює сценарій, коли впевненість у тому, що "висновок 1" зумовлений "умовою 1", становить менше ніж 100%.

Загалом, такі системи можуть бути двох різних типів. Один з них – кон'юнктивні БЗ, де кожен попередній атрибут правила з'єднується за допомогою логічного оператора. Інший тип – диз'юнктивні БЗ, де в попередній частині правила використовується логічний оператор OR. Кон'юнктивна БЗ потребує більше обчислювального часу, оскільки є прикладом комбінаторної вибухової задачі, що виникає внаслідок з'єднання попередніх атрибутів правила логічним оператором AND. Отже, база правил кон'юнктивного типу складається з великої кількості правил. Диз'юнктивна БЗ, навпаки, потребує менше обчислювального часу, оскільки в ній використовується логічний оператор OR в антецедентній частині правила, а отже, і менша кількість правил загалом.

Останнім часом глибоке навчання стає ефективним методом для розв'язання різних типів задач зокрема регресійним методом завдяки своїй здатності обробляти сирі дані безпосередньо. Однак Deep Learning не має можливості вирішувати різні типи невизначеності, оскільки воно базується на нейронних мережах, які за своєю природою обмежені в роботі з невизначеністю [7, 8]. З іншого боку, система на основі правил здатна вирішувати різні типи невизначеності, такі як незнання, неповнота, масштабність, розпливчастість і неточність в інтегрованій роботі. Однак такі системи не мають можливості інтегрувати асоціативну пам'ять у процедуру виведення, оскільки більшість операцій базуються на множенні, підсумовуванні та діленні. Оскільки ці оператори не мають можливості запам'ятовування, вони не здатні виявляти повні патерни з часткової інформації. Наприклад, використання ступенів відповідності при обчисленні ваги активації правила за допомогою операторів множення та ділення не дозволяє отримати точні значення активації кожного правила в системі виведення. Ці неповні значення впливатимуть на процедуру агрегації правил, яка використовується для побудови прогнозу. Тому в цьому дослідженні розглядаються методи, засновані на глибокому навчанні, зокрема, глибока нейронна мережа (DNN), для розрахунку ваги активації правила з урахуванням ступенів збігу, що дозволяє обчислювати більш точні значення активованого правила. Причиною використання методу глибокого навчання на основі DNN є те, що він базується на штучних нейронних мережах (ШНМ). ШНМ – це системи асоціативної пам'яті, а отже, здатність відновлювати цілісні ситуації з часткової інформації, а також здатність співвідносити вхідні дані з інформацією, що зберігається в пам'яті. Таким чином, запропонований нами метод базується на асоціативній пам'яті, що дозволяє отримати повне значення ваги активації правил з урахуванням ступенів співпадіння. Це відіграватиме важливу роль при побудові системи виведення для дуже точної обробки особливо великих обсягів даних про процес буріння НГС.

#### Аналіз останніх джерел

Глибоке (глибинне) навчання [9 – 13] використовується для вирішення різних проблем прогнозування на основі даних. Однак, для підвищення точності прогнозування використовуються різні алгоритми, які покращують точність прогнозування. Зокрема метод «випадкового лісу» [14, 15] використовується як техніка глибокого навчання для покращення задач класифікації. У запропонованому дослідженні глибинне навчання було використано для вилучення високорівневих ознак режимних параметрів процесу буріння і передачі їх алгоритму випадкового лісу для виконання завдань класифікації.

У задачах прогнозування транспортних потоків [16] можна спостерігати поєднання теорії нечітких обчислень та глибокої залишкової мережі для вирішення проблеми невизначеності. Такі системи, як правило, містять ряд модулів, а саме: вхідні дані, глибоку згорткову мережу, нечітку мережу, модуль злиття та предиктор. На початку вхідні дані передаються одночасно до нечіткої мережі і глибокої згорткової мережі. Після обробки даних вони об'єднуються в модуль злиття і надсилаються до модуля предиктора. Модуль злиття використовує цільові функції або функції втрат для навчання параметрів модулів нечіткої мережі і глибокої згорткової мережі. Під час фази навчання відповідні параметри модифікуються таким чином, щоб мінімізувати значення цільової функції. Після завершення фази навчання можна згенерувати прогнозовані значення, ввівши дані в модель. Модуль глибокої згорткової мережі використовується для виявлення закономірностей даних, тоді як сама нечітка мережа використовується для усунення невизначеності.

Однак нечіткі системи не можуть врахувати невизначеність через неповноту та незнання, що

заважатиме точності прогнозування. Крім того, бізнес-логіка задачі, як правило, включає складні дані, оскільки складається з просторової та часової інформації. Таким чином, ці дані спричинятимуть неповноту через відсутність інформації та незнання через невідповідність даних. Оскільки такі типи невизначеностей не можуть бути вирішені за допомогою нечітких систем, вони впливатимуть на точність прогнозування.

Ієрархічна злита нечітка глибинна нейронна мережа [17] використовується як основний інструмент класифікації даних. Дані передаються до нечіткої системи та модуля глибинної нейронної мережі одночасно, а потім вихідні дані цих двох модулів об'єднуються для передачі до шару, керованого завданням, для отримання результату класифікації. Фазифікація нечіткого модуля відповідно допомагає впоратися з невизначеністю, а глибоке навчання знижує рівень шуму в даних. Однак такі мережі страждають від притаманного нечітким системам обмеження, яке полягає у відсутності вирішення проблеми невизначеності через неповноту та незнання.

### Виклад основного матеріалу

В умовах збільшення пошуково-розвідувального буріння в Україні, передбаченого енергетичною стратегією [18], важливого значення набувають питання оптимального управління процесом буріння свердловин, яке передбачає таку організацію робіт і такий вибір технологічного обладнання та параметрів режиму буріння, при яких собівартість буріння свердловин при загальному часі її спорудження досягає мінімального значення. Оперативне вирішення задачі оптимізації буріння у теперішній час неможливе внаслідок відсутності адекватних математичних моделей процесу, які б відображали у повній мірі взаємозв'язки параметрів технологічного процесу буріння. Бурова установка, за допомогою якої здійснюється технологічний процес буріння свердловин, з точки зору керування нею, є багатомірним складним керованим об'єктом, який функціонує за умов апріорної та поточної невизначеності під впливом суттєвих зовнішніх збурень і має декілька каналів для передачі як керувальних впливів, так і збурень, зумовлених унікальними властивостями бурових установок і взаємодією системи з навколишнім середовищем. Параметризація процесу буріння нафтогазових свердловин включає в себе встановлення та контроль цих впливів і збурень для забезпечення ефективності буріння.

В залежності від характеру впливу на процес буріння, мети керування і можливостей вимірювання, ці параметри можна розділити на групи як показано на рисунку 1 і 2.

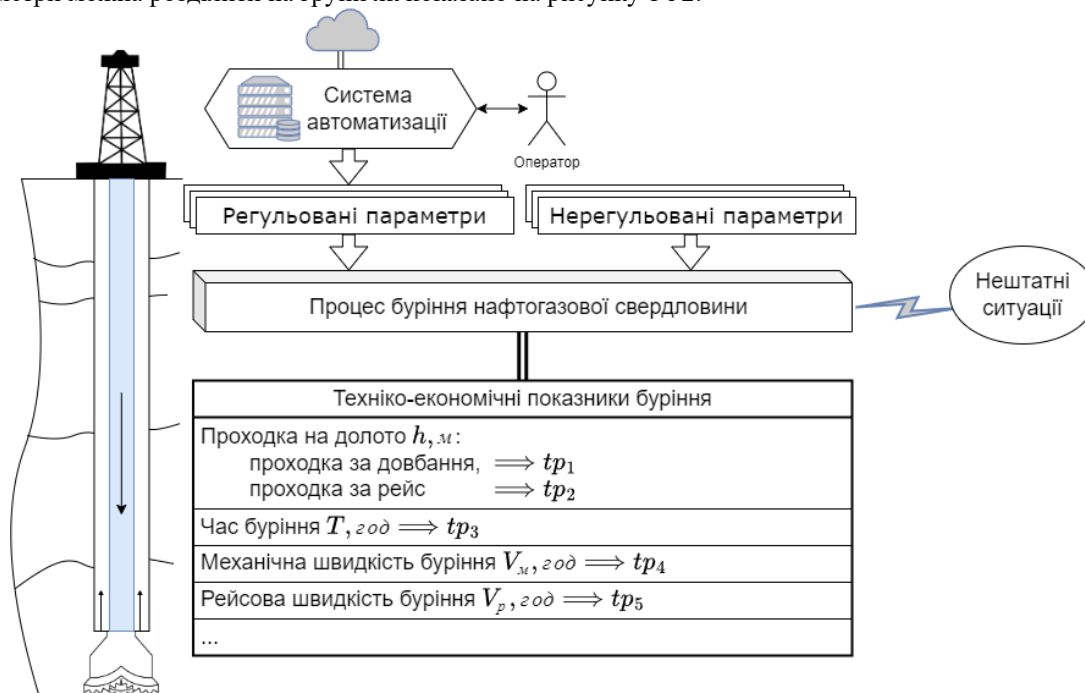


Рисунок 1 - Структура моделі технологічного процесу буріння свердловин

Перша група змінних – це регульовані впливи, що діють на вході об'єкта, а саме: осьова сила, що діє на бурове долото, частота обертання долота, витрата промивної рідини і її характеристики (густина, в'язкість, водневий показник, вміст піску, швидкість витікання з насадок долота). Бурові установки дозволяють у широкому діапазоні здійснювати регулювання осьової сили на долото, тому вона вважається головним керувальним впливом. Для регулювання частоти обертання долота можливості більше обмежені, тому що при роторному бурінні вона змінюється ступенево, а при бурінні турбобурами і електробурами швидкість протягом рейсу долота не регулюється і залежить лише від осьової сили на долото.

Другу групу створюють нерегульовані параметри, які залежать від режиму буріння. Це тип бурового долота, його діаметр, кількість шарошок, геометрія зубців, глибина свердловини, параметри бурильної колони, параметри бурової установки. Вони характеризують умови протікання технологічного процесу. До цієї групи можна віднести збурюючі впливи: силу статичного опору, тертя колони бурильних труб об стінки свердловини, фізико-механічні і абразивні властивості гірських порід, пластові тиски, температуру в

свердловині та ін.

Третю групу складають показники процесу буріння, які залежать від вхідних параметрів: механічна швидкість буріння, проходка бурового долота, рейсова швидкість буріння, зношення оснащення і опор долота та ін..

Бурові установки характеризуються вантажопідйомністю, висотою вежі, потужністю і типом приводу, типом укриття, характером обігріву або кондиціонування, і рівнем механізації або автоматизації, а також рівнем приготування і очищення бурового розчину. Усього державним стандартом передбачено 8 класів бурових установок для буріння на глибину від 2000 до 10000м. Більше ніж 50% установок в країнах СНД мають дизельний привід. Потужність дизелів в одному агрегаті до 740 кВт. Ці характеристики також мають опосередкований вплив на параметризацію процесу буріння нафтогазових свердловин.

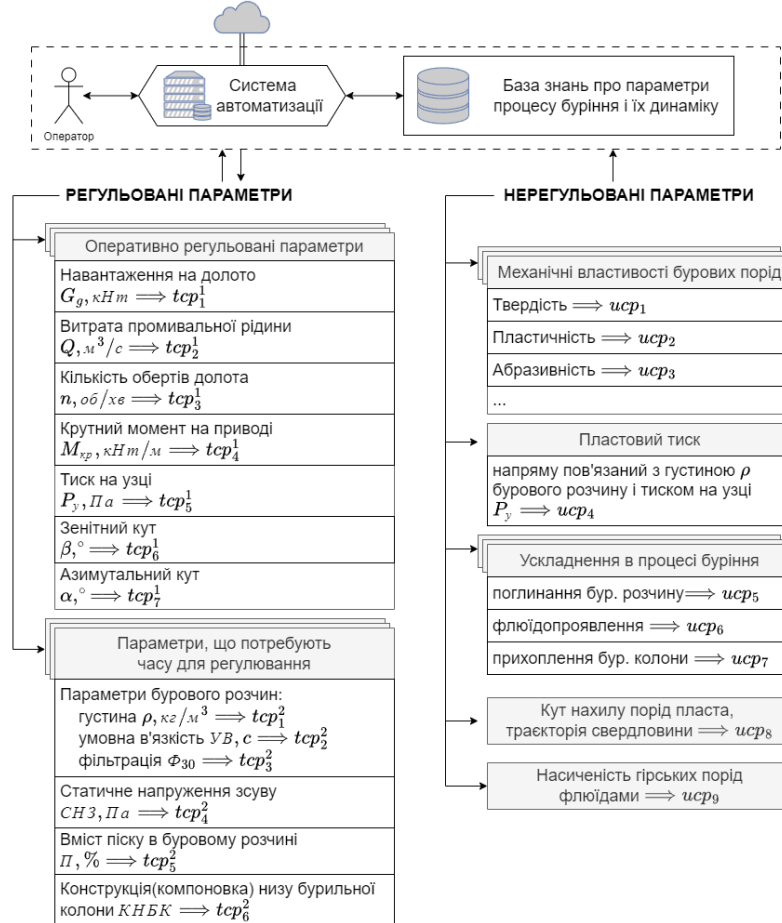


Рисунок 2 – Параметризація процесу буріння НГС

У загальному випадку правило складається з двох частин: одна з них – антецедентна частина або частина передумови, яка складається з антецедентних атрибутів; в той час як інша – наслідок або частина висновку, яка містить наслідковий атрибут, як показано у рівнянні (1). Антецедентні атрибути використовують референтні значення, а ступені достовірності пов'язані з наступним атрибутом правила, як показано у рівнянні (2). Кожному правилу присвоюється вага, яка показує його важливість.

Існує певна залежність між наборами параметрів процесу буріння. У загальному випадку правило представлено стрілкою матиме вигляд:

$$\{\{tcp_i\}^i, \{ucp_j\}^j\} \rightarrow \{\{tp_k\}^k\} \quad (1)$$

де  $\{tcp_i\}, \{ucp_j\}$  – антецедентні регульовані і нерегульовані атрибути відповідно;  $\{tp_k\}$  – наслідкові (консеквентні) атрибути.

$$Rule_L: \left\{ \begin{array}{l} IF \{ \{tcp_i = v_{tcp}^i\} \}, \\ \dots \\ THEN (\{tp_1\}^1; weight^1), (\{tp_2\}^2; weight^2), \dots, (\{tp_k\}^k; weight^k) \end{array} \right. \quad (2)$$

де  $Rule_L$  – правила з набору;  $weight^k$  – ваги.

Зазвичай, набір правил називається базою правил (RulesBase). Логічні зв'язки атрибутів антецедента у правилі можуть бути або AND, або OR. Правило вважається кон'юнктивним, якщо попередні атрибути з'єднані за допомогою AND. Аналогічно, якщо попередні атрибути правила з'єднані за допомогою OR, то воно називається диз'юнктивним. На основі логічної зв'язності таку конструкцію можна назвати кон'юнктивною або диз'юнктивною.

Обчислення ваг для кон'юнктивної конструкції відбувається за формулою:

$$weight_k = \frac{weight(Rule_L) \times \prod_{i=1} rd_{ki}}{\sum_{i=1} [weight(Rule_L) \times \prod_{i=1} rd_{Li}]} \quad (3)$$

Обчислення ваг для диз'юнктивної конструкції відбувається за формулою:

$$weight_k = \frac{weight(Rule_L) \times \prod_{i=1} rd_{ki}}{\sum_{i=1} [weight(Rule_L) \times \sum_{i=1} rd_{Li}]} \quad (4)$$

Процедура виведення складається з різних кроків, які проілюстровано на рисунку 3. До них відносяться перетворення вхідних даних, активація правил, обчислення ваг, оновлення ступеня зважування та агрегація правил. Вхідні дані розподіляються за еталонними значеннями попередніх атрибутів, що називається ступенем відповідності, що досягається за допомогою процесу перетворення вхідних даних. Тоді правила називаються пакетом антецедентів. Згодом обчислюються ваги активації правил з використанням ступенів відповідності.

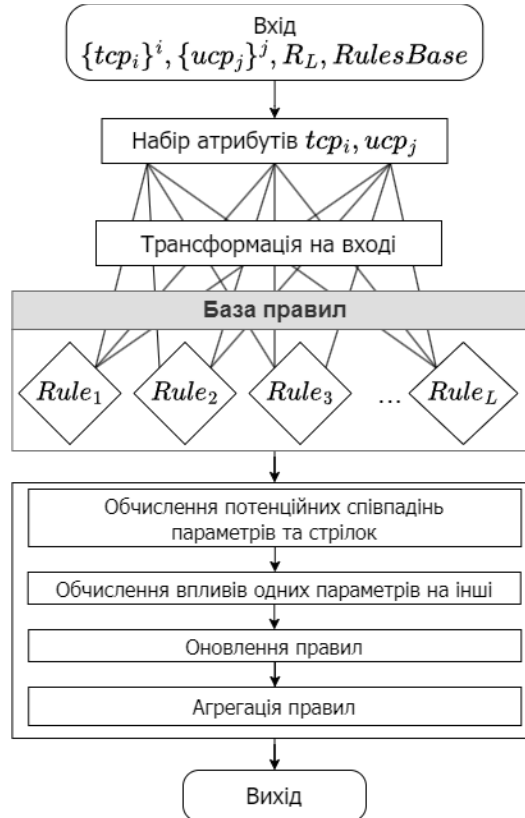


Рисунок 3 – Схема роботи системи на основі правил

Оновлення впевненостей відбувається за формулою:

$$CF_k = \overline{CF}_k \frac{\sum_{t=1} \lambda_t \times \sum_{i=1} rd_{ki}}{\sum_{t=1} \lambda_t} \quad (5)$$

де  $\lambda_i = \begin{cases} 1, & \text{якщо атрибут використовується при визначенні правила } Rule_L, \\ 0, & \text{якщо атрибут НЕ використовується} \end{cases}$

$\overline{CF}_k$  – початковий ступінь впевненості.

Нечітке вихідне значення процедури агрегації правил конвертується у чітке значення з використанням коефіцієнтів релевантності, як показано у рівнянні (6). Це значення вважається кінцевим результатом.

$$cf_k = \sum_{i=1} [CF_k \times uf_L] \quad (6)$$

де  $cf_k$  – очікуване числове значення;  $uf_L$  – коефіцієнт релевантності.

Глибоке навчання – це метод, який автоматично виявляє необхідне представлення з даних для розрахунку прогнозування або класифікації. Найпростіша форма глибокого навчання складається з вхідного, прихованого та вихідного шарів. Зазвичай дані подаються на вхідний шар і передаються на прихований шар. Прихований шар може містити декілька шарів. Кілька прихованих шарів позначаються словом "Deep". Кожен шар має декілька нейронів. Кожен нейрон має функцію активації, яка створює нелінійне представлення даних. Нейрон допомагає представити особливості цих даних.

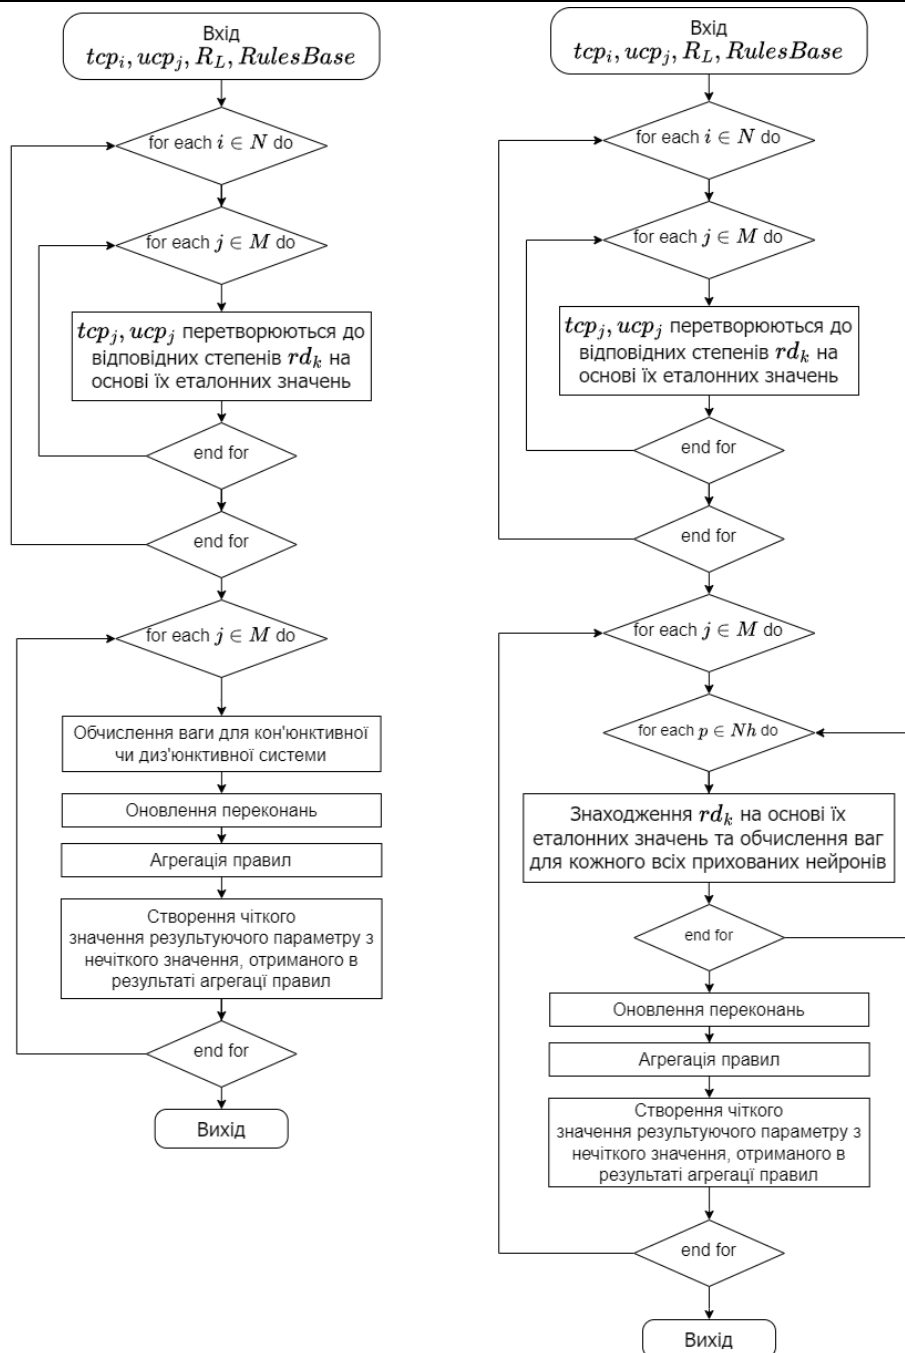


Рисунок 4 – Порівняння алгоритмів представлення та трансформації системи на основі правил до і після впровадження прихованих нейронних шарів

Спочатку вхідні дані зіставляються з відповідними ступенями еталонних значень попередніх атрибутів під час ініціалізаційного перетворення вхідних даних. Другим кроком є обробка вхідних даних засобами глибокого навчання. На цьому кроці застосовуються різні методи глибокого навчання такі як DNN(Deep Learning Network), LSTM (довга короткочасна пам'ять) та CNN (згорткові нейронні мережі). На цьому етапі будується багатошаровий нейрон, який має один вхідний шар, декілька прихованих шарів і один вихідний шар. Ступінь відповідності з кроку перетворення вхідних даних передається до вхідного шару. Кількість нейронів у вхідному шарі зазвичай дорівнює загальній кількості еталонних значень. Всі нейрони повністю з'єднані між собою. Вихідний шар містить таку саму кількість нейронів, що і кількість правил. Вихідний шар виробляє вагу активації для метаправил, які активують базові правила. Ваги нейронів ініціалізуються випадковими значеннями, а зміщення нейронів ініціалізуються нулем.

Третім кроком є оновлення впевненостей експертів, яке допомагає врахувати невизначеність, пов'язану з відсутністю попередньої ознаки. Четвертий крок - агрегація правил. Цей крок генерує нечітке значення. Нечітке значення пізніше перетворюється в чітке значення, яке є прогнозованим результатом. Схеми вірогідності, оновлення ступеня впевненості, висновок на основі доказових міркувань враховують невизначеність, пов'язану з нечіткістю, неточністю та розмитістю значень режимних параметрів процесу буріння.

### Висновки

У запропонованому нами методі додано шар глибокої обробки, який замінив крок обчислення активаційної ваги в системі на основі правил. В якості методу глибокого навчання використовується багатощарова нейронна мережа. Шар глибокої обробки містить асоціативну пам'ять. Крок розрахунку активаційної ваги використовує оператори множення, підсумовування та ділення з використанням відповідних степенів та ваг правил. Таким чином, на цьому кроці відсутній будь-який компонент асоціативної пам'яті, що призводить до неповного обчислення ваг активації правил. Однак рівень глибокої обробки дозволяє обчислити повні значення ваг активації правил. Тому запропоноване рішення є інтеграцією методу глибокого навчання на основі асоціативної пам'яті в процедурах виведення, що дозволяє більш точно прогнозування в умовах невизначеності.

Крім того, в процесі навчання включено додаткові параметри, такі як ваги та зміщення нейронів, що відіграло важливу роль у підвищенні точності прогнозування. Таким чином, типовий фреймворк виведення був вдосконалений завдяки включенню глибокої нейронної мережі. Цей новий метод був застосований для прогнозування динаміки режимних параметрів процесу буріння нафтогазової свердловини. Виходячи з отриманих результатів, можна стверджувати, що значне покращення точності прогнозування було досягнуто за допомогою нового методу, запропонованого в цьому дослідженні.

### Література

1. CUI, Junbiao; LIANG, Jiye. Fuzzy Learning Machine. *Advances in Neural Information Processing Systems*, 2022, 35: 36693-36705.
2. Mi Y, Shi Y, Li J, Liu W, Yan M. Fuzzy-based concept learning method: Exploiting data with fuzzy conceptual clustering. *IEEE transactions on cybernetics*. 2020 Apr 7;52(1):582-93.
3. PAULLADA, Amandalynne, et al. Data and its (dis) contents: A survey of dataset development and use in machine learning research. *Patterns*, 2021, 2.11.
4. Lu S, Guo D, Ren S, Huang J, Svyatkovskiy A, Blanco A, Clement C, Drain D, Jiang D, Tang D, Li G. Codexglue: A machine learning benchmark dataset for code understanding and generation. *arXiv preprint arXiv:2102.04664*. 2021 Feb 9.
5. REDDY, Bharath; FIELDS, Richard. From past to present: a comprehensive technical review of rule-based expert systems from 1980--2021. In: *Proceedings of the 2022 ACM Southeast Conference*. 2022. p. 167-172.
6. Dattachaudhuri A, Biswas SK, Chakraborty M, Sarkar S. A transparent rule-based expert system using neural network. *Soft Computing*, 2021 Jun;25:7731-44.
7. BEGHETTO, Ronald A. Uncertainty. In: *The Palgrave Encyclopedia of the possible*. Cham: Springer International Publishing, 2023. p. 1691-1697.
8. GAWLIKOWSKI, Jakob, et al. A survey of uncertainty in deep neural networks. *arXiv preprint arXiv:2107.03342*, 2021.
9. BUDUMA, Nithin; BUDUMA, Nikhil; PAPA, Joe. *Fundamentals of deep learning*. " O'Reilly Media, Inc.", 2022.
10. WANG, Xizhao; ZHAO, Yanxia; POURPANAH, Farhad. Recent advances in deep learning. *International Journal of Machine Learning and Cybernetics*, 2020, 11: 747-750.
11. DONG, Shi; WANG, Ping; ABBAS, Khushnood. A survey on deep learning and its applications. *Computer Science Review*, 2021, 40: 100379.
12. MATHEW, Amitha; AMUDHA, P.; SIVAKUMARI, S. Deep learning techniques: an overview. *Advanced Machine Learning Technologies and Applications: Proceedings of AMLTA 2020*, 2021, 599-608.
13. BARANIUK, Richard; DONOHO, David; GAVISH, Matan. The science of deep learning. *Proceedings of the National Academy of Sciences*, 2020, 117.48: 30029-30032.
14. NGUYEN, Jean-Michel, et al. Random forest of perfect trees: concept, performance, applications and perspectives. *Bioinformatics*, 2021, 37.15: 2165-2174.
15. BORUP, Daniel, et al. Targeting predictors in random forest regression. *International Journal of Forecasting*, 2023, 39.2: 841-868.
16. GEORGE, Shiju; SANTRA, Ajit Kumar. Fuzzy inspired deep belief network for the traffic flow prediction in intelligent transportation system using flow strength indicators. *Big Data*, 2020, 8.4: 291-307.
17. PHAM, Phu, et al. A hierarchical fused fuzzy deep neural network with heterogeneous network embedding for recommendation. *Information Sciences*, 2023, 620: 105-124.
18. M. Chesanovsky, K. Kravtsov, V. Protsiuk, L. Poteraiilo, Software outlines for decisions making support in oil and gas engineering, *Scientific Papers of Silesian University of Technology: Organization and Management Series*, Issue No. 151., pp.81-99.