

ВОВК РОМАН

Івано-Франківський національний технічний університет нафти і газу

<http://orcid.org/0000-0003-0681-4534>e-mail: roman.vovk@nuing.edu.ua**ТРИЩ ВЛАДИСЛАВ**

Івано-Франківський національний технічний університет нафти і газу

<https://orcid.org/0009-0000-8564-1752>e-mail: vlad.trishch@gmail.com**БОГДАН ОЛЕКСІЙ**

Івано-Франківський національний технічний університет нафти і газу

<https://orcid.org/0009-0000-9539-6359>e-mail: oleksiibohdan@gmail.com

МЕТОДОЛОГІЯ ОПТИМІЗАЦІЇ ІНТЕЛЕКТУАЛЬНИХ СИСТЕМ НА ОСНОВІ ДАНИХ З ПРАВИЛ ВПЕВНЕНOSTІ

У даній статті розглядається проблема підвищення ефективності інтелектуальної системи прийняття рішень на основі бази нечітких правил шляхом її оптимізації за параметрами та структурою. Запропоновано гібридний підхід, що поєднує алгоритм диференціації для налаштування параметрів навчання та алгоритм стратегічної евристики для модифікації структури бази правил. Розроблено циклічний процес оптимізації, який дозволяє покращити точність і адаптивність моделі шляхом поступового коригування вагових коефіцієнтів, рівнів впевненості та кількості фазифікованих правил. Визначено критерій зупинки процесу оптимізації, що забезпечує баланс між продуктивністю та обчислювальною ефективністю. Проведено дослідження, які підтверджують переваги розробленого підходу порівняно з традиційними методами налаштування бази нечітких правил. Отримані результати можуть бути застосовані у сфері прогнозування та аналізу даних, управління складними технологічними процесами, енергетиці, кібербезпеці, тощо.

Ключові слова: інтелектуальні системи на основі правил, дані, оптимізація, навчання, еволюційний алгоритм, диференціальна еволюція, адаптивність моделі.

VOVK ROMAN, TRISHCH VLADYSLAV, BOHDAN OLEKSIY

Ivano-Frankivsk National Technical University of Oil and Gas

METHODOLOGY FOR OPTIMIZING INTELLIGENT SYSTEMS BASED ON DATA FROM CONFIDENCE RULES

This article addresses the problem of increasing the efficiency of intelligent decision support systems through the implementation of fuzzy rules, with a central focus on the fuzzification of rule antecedents and consequents. A hybrid approach is proposed that incorporates an evolutionary algorithm for optimizing the learning parameters of fuzzy sets and a heuristic algorithm for adaptively adjusting the structure of the fuzzy rule base. A cyclical optimization process is developed to ensure a gradual improvement in model accuracy and adaptability by adjusting weighting coefficients, fuzziness levels, and the number of fuzzy rules. A stopping criterion for the optimization process is defined, guaranteeing a balance between system performance and computational efficiency. The proposed methodology integrates the concept of intelligent systems with the use of fuzzified antecedents and consequents, contributing to the enhanced accuracy of modeling and predicting optimal control parameter values. The optimization approach is based on principles where the evolutionary algorithm fine-tunes the parameters of the fuzzy sets, while the heuristic algorithm adaptively modifies the structure of the fuzzy rule base. This allows for an effective balance between expanding and narrowing the solution search space, which in turn improves the quality of the optimization results and the system's ability to adapt to changing environmental conditions. Furthermore, the developed learning mechanism for systems based on fuzzy rules enhances decision-making accuracy under conditions of high uncertainty through adaptive parameter adjustments and structural component optimization. The results demonstrate the high efficiency of the proposed approach, reducing the risk of erroneous decisions and improving system performance under unstable input conditions. The application of this methodology is promising in fields such as forecasting and data analysis, the management of complex technological processes, energy, cybersecurity, automated control systems, and other high-tech industries that require flexible and adaptive optimization approaches considering the fuzzy nature of input data and decisions.

Key words: rule-based intelligent systems, data, optimization, learning, evolutionary algorithm, differential evolution, model adaptability.

Стаття надійшла до редакції / Received 11.04.2025

Прийнята до друку / Accepted 26.04.2025

Постановка задачі

Метою даного дослідження є підвищення ефективності інтелектуальної системи на основі бази правил впевненості шляхом розробки та впровадження комплексного підходу до її оптимізації. Це передбачає вдосконалення як параметрів бази правил, що впливають на точність оцінки, так і її структури, що визначає якість логічних висновків. Реалізація даної мети сприятиме покращенню адаптивності моделі бази правил, її здатності до навчання та коригування відповідно до змінних умов. Це, у свою чергу, дозволить підвищити точність, надійність і швидкість прийняття рішень у складних невизначених середовищах, таких як експертні системи, діагностика, прогнозування та управління складними технологічними процесами, зокрема в нафтогазовій промисловості України.

Аналіз останніх джерел

Моделі оптимізації для інтелектуальних систем на основі правил, як правило орієнтовані на налаштування параметрів за допомогою нелінійного обмеженого розв'язувача із набору інструментів оптимізації MATLAB [1]. В основі цього підходу лежить алгоритм послідовного квадратичного програмування, який є детермінованим методом. Проте через градієнтний механізм пошуку цей підхід схильний до потрапляння у локальні мінімуми, що обмежує його ефективність у нелінійних задачах. Крім того, при зростанні розмірності задачі швидкість збіжності значно зменшується, що підвищує обчислювальні витрати.

Обмеження даного підходу, представлено в [2], де зазначається, що його продуктивність значною мірою залежить від початкових умов. У зв'язку з цим дослідження рекомендує саме еволюційні алгоритми, які показали високу ефективність у розв'язанні задач із нелінійним і безперервним простором пошуку. Для оптимізації системи застосовувався алгоритм клонального відбору (CSA - *Clonal Selection Algorithm*).

Окрім цього, для навчання інтелектуальної системи використовувалися й інші еволюційні алгоритми, зокрема оптимізація рою часток [3] та методологія диференціальної еволюції [4], при цьому даний метод продемонстрував найкращу ефективність, оскільки було запропоновано спільну оптимізацію для інтелектуальної системи на основі правил, яка передбачає оптимізацію як структури, так і її параметрів. У цьому підході середньоквадратичну помилку було замінено на помилку узагальнення, засновану на теоремі нерівності Гефдінга. Для оптимізації структури використовувався евристичний алгоритм, а параметри налаштовувалися за допомогою диференціальної еволюції. Дослідження даного напрямку демонструють здатність системи до узагальнення та підтвердили ефективність використання методології оптимізації параметрів. Водночас, запропонований підхід не включав механізму автоматичного налаштування керуючих параметрів, що могло б ще більше покращити результати. Ряд досліджень даного напрямку присвячено пошуку оптимальних значень керуючих параметрів. Одним із перспективних підходів є адаптивне керування параметрами, що забезпечує автоматичне визначення майже оптимальних значень коефіцієнта мутації та коефіцієнта кросингверу завдяки своїй простоті [5].

В [6-7] було запропоновано фазі-адаптивну диференціальну еволюцію (FADE - *Fuzzy Adaptive Differential Evolution*), яка використовує нечіткий логічний контролер для автоматичного налаштування значень коефіцієнтів мутації та кросингу. Проте системи, засновані на фазі логіки, здатні враховувати лише неточність, що обмежує їхню ефективність у випадках, коли присутні складніші типи невизначеності.

В дослідженнях [8-9] було представлено жадібну адаптивну диференціальну еволюцію (GADE - *Greedy Adaptive Differential Evolution*), яка застосовує жадібний алгоритм пошуку для вибору найкращих керуючих параметрів, орієнтуючись на сусідні точки популяції. Однак, подібно до попереднього випадку, цей метод не враховує невизначеність цільової функції, що може обмежувати його застосування в складних задачах. Автори запропонували нову модифікацію алгоритму диференціальної еволюції, у якій керуючі параметри адаптуються на основі історії їхнього успішного використання. Крім того, у цьому підході застосовано механізм поступового зменшення розміру популяції на кожній ітерації. Проте, дана модифікація також не враховує невизначеність цільової функції, що обмежує його застосування для інтелектуальних систем.

Оглянуті дослідження показують, що спільна оптимізація структури та параметрів інтелектуальної системи на основі правил перевершує окремі оптимізаційні підходи. Серед еволюційних алгоритмів диференціальна еволюція є найперспективнішою завдяки своїй здатності ефективно долати численні локальні мінімуми. Однак відсутність механізму автоматичного визначення оптимальних значень керуючих параметрів із врахуванням невизначеності цільової функції залишається суттєвою проблемою.

Ключовим викликом також є знаходження оптимальних значень керуючих параметрів, що забезпечують баланс топології простору пошуку рішень. Це питання є критичним для застосування існуючих методик, таких зокрема, як оптимальної процедури навчання для інтелектуальної системи на основі правил впевненості. Відповідно, необхідний новий підхід до навчання, що дозволить підвищити точність прогнозування шляхом адаптивної оптимізації параметрів.

Виклад основного матеріалу

На сьогодні інтелектуальні системи на основі правил знаходять широке застосування в різних сферах, оскільки вони забезпечують ефективну методологічну основу для роботи з якісними та кількісними даними, враховуючи різні типи невизначеності. Важливим аспектом функціонування таких систем є процес навчання, який сприяє оновленню бази знань та налаштуванню параметрів, необхідних для підвищення точності прогнозування.

У якості механізмів навчання використовуються різноманітні оптимізаційні алгоритми, зокрема оптимізація рою часток (PSO - *Particle Swarm Optimisation*), диференціальна еволюція (DE - *Differential Evolution*), генетичний алгоритм (GA - *Genetic Algorithm*) тощо. Оглянуті дослідження свідчать, що серед цих підходів алгоритм диференціальної еволюції демонструє найвищу ефективність. Водночас його продуктивність значною мірою залежить від належного налаштування керуючих

параметрів, зокрема коефіцієнтів кросовингу та мутації.

З огляду на зазначене, дане дослідження має на меті представити покращений оптимізований процес навчання інтелектуальної системи на основі правил шляхом інтеграції диференціальної еволюції. Даний метод це застосування алгоритму покращеної адаптивної диференціальної еволюції на основі правил, оскільки він дозволяє ефективно визначати наближено оптимальні значення керуючих параметрів, забезпечуючи збалансований процес пошуку та дослідження простору рішень.

Крім того, у роботі представлено механізм спільної оптимізації навчання на основі алгоритму адаптивної диференціальної еволюції на основі правил, який передбачає одночасне врахування параметрів та структури інтелектуальної системи. Отримані результати демонструють, що застосування даного алгоритму забезпечує вищу точність прогнозування порівняно з іншими методами оптимізації, що підтверджує його ефективність у задачах навчання інтелектуальних систем на основі правил.

Інтелектуальна система на основі правил впевненості (ІСПВ) є потужним інструментом для моделювання невизначених знань, що реалізується через включення структури правил у процес виведення. Типова архітектура інтелектуальної системи складається з двох основних компонентів: бази знань та механізму виведення.

У традиційних інтелектуальних системах знання зазвичай представляються у вигляді продукційних правил типу "ЯКЩО-ТОДІ". Наприклад, правило "ЯКЩО вміст сірководню в природному газі перевищує встановлені норми, ТОДІ необхідно провести очищення газу" передбачає абсолютну впевненість у висновку. Проте, в реальних умовах такий детермінований підхід є недосконалим, оскільки не враховує ступінь невизначеності.

З метою подолання цього обмеження пропонується вдосконалений підхід до представлення знань, що передбачає включення ступеню впевненості у наслідкову частину правила "ЯКЩО-ТОДІ". Наприклад:

"ЯКЩО вміст сірководню в газі "високий" (впевненість 0.9) і швидкість вітру "висока" (впевненість 0.7), ТО ризик виникнення аварійної ситуації "високий" (впевненість 0.8)".

Цей підхід дозволяє моделювати невизначеність, надаючи можливість інтелектуальній системі працювати з неповними або нечіткими даними. Для реалізації виведення в такій інтелектуальній системі використовується евідентне міркування, що здатне ефективно враховувати невизначеність у процесі прийняття рішень.

Завдяки цим властивостям такі системи знаходять застосування у різних галузях, включаючи прогнозування виявлення нештатних ситуацій при бурінні нафтових і газових свердловин, природних катастроф, медичну інформатику, автоматизоване управління, де невизначеність відіграє ключову роль у процесі ухвалення рішень.

База знань системи формується на основі бази правил структурованих за двома основними типами:

- *Кон'юнктивна база правил* – антецеденти правил поєднані кон'юнктивним оператором (логічне "І"). Основним недоліком цього підходу є проблема комбінаторного вибуху, що суттєво ускладнює обчислювальні процеси.

- *Диз'юнктивна база правил* – антецеденти з'єднані диз'юнктивним оператором (логічне "АБО"). Цей тип бази знань позбавлений проблеми комбінаторного вибуху, що значно знижує обчислювальну складність і підвищує ефективність роботи системи.

Отже, ІСПВ є гнучкою та адаптивною системою для моделювання невизначеності, що дозволяє підвищити точність і надійність прогнозування у складних системах прийняття рішень.

Ефективність ІСПВ значною мірою залежить від визначення оптимальних значень параметрів навчання, включаючи вагові коефіцієнти правил, атрибутів та значення впевненості. Для досягнення високої точності прогнозування в ІСПВ застосовуються різні методи оптимізації параметрів, а процес їхньої оптимізації може розглядатися як механізм навчання системи.

У традиційних підходах ці параметри, як правило, визначаються експертами, що є обмеженням для великих наборів даних і може призводити до неточних результатів. Для покращення точності передбачень у ІСПВ можна використовувати численні оптимізаційні процедури навчання. До найпоширеніших підходів належать послідовне квадратичне програмування, оптимізація рою часток (PSO) та диференціальна еволюція (DE).

Механізми навчання ІСПВ поділяються на два основні типи:

- *Оптимізація структури* – визначення оптимальної кількості референтних значень правил бази знань.

- *Оптимізація параметрів* – пошук оптимальних значень параметрів навчання.

Комбінування цих підходів у спільну оптимізацію забезпечує значне підвищення продуктивності системи.

Програмування широко застосовується для параметричної оптимізації, проте воно схильне до потрапляння у локальні мінімуми, що ускладнює знаходження глобального оптимуму. Цю проблему вирішують еволюційні алгоритми, що завдяки стохастичному пошуку можуть досліджувати простір рішень ефективніше.

Серед еволюційних алгоритмів диференціальна еволюція демонструє найкращі результати у навчанні ІСПВ завдяки своїм адаптивним стратегіям оптимізації. Основними компонентами методи є:

1. *Експлуатація* – процес генерації нового рішення на основі інформації з поточного пошуку.
2. *Дослідження* – механізм розширеного пошуку, що запобігає потраплянню в локальні мінімуми.

Визначальну роль у продуктивності методології відіграють керуючі параметри, зокрема коефіцієнт мутації та коефіцієнт кросингверу. Проте точний підбір цих параметрів є складним завданням, і традиційно їх визначають методом проб і помилок, що є часовитратним. Відповідно, існує зростаючий інтерес до розробки алгоритмів, здатних автоматично прогнозувати оптимальні значення цих параметрів.

У цьому дослідженні пропонується підхід до оптимізації параметрів ІСПВ шляхом інтеграції диференціальної еволюції. Запропонований алгоритм, названий покращеною адаптивною диференціальною еволюцією на основі бази правил, спрямований на автоматизоване визначення оптимальних значень керуючих параметрів, забезпечуючи баланс між пошуком та експлуатацією.

Диференціальна еволюція (*Differential evolution*) є ефективним підходом до оптимізації параметрів у процесі навчання завдяки своїй здатності уникати локальних мінімумів і наближатися до глобальних оптимальних розв'язків. Методологія належить до класу стохастичних популяційних метаевристичних алгоритмів. Основу становить популяція, яка містить множину особин, де кожна особина є можливим розв'язком задачі. Протягом процесу оптимізації популяція еволюціонує від однієї ітерації до іншої, поступово покращуючи якість розв'язків.

На рисунку 1 ілюструється загальна схема роботи методології :

- *Ініціалізація популяції* – на початковому етапі створюється початкова популяція особин.
- *Мутація* – для кожної особини генерується мутоване (донорське) рішення за допомогою фактора мутації.
- *Кросингвер* – комбінуються вихідні та мутовані особини за допомогою фактора кросовингу, утворюючи пробну популяцію.
- *Відбір* – формується нова популяція шляхом порівняння початкових та пробних особин, вибираючи найбільш придатні рішення.
- *Перевірка критеріїв зупинки* – якщо виконано один із критеріїв зупинки, тоді найкраще рішення з поточної популяції розглядається як оптимальне. Якщо критерій зупинки не досягнуто, процес повторюється.




Рисунок 1 – Алгоритмічна схема алгоритму диференціальної еволюції

У даному контексті $[Item_{i,it}]$ позначає i -ту особину в популяції на it -ій ітерації, де $i = 1, 2 \dots Size$, а $Size$ визначає загальний розмір популяції. Кожна особина $[item_i] \in N$ -вимірним вектором, представленим як $Item_i = (Item_{i,1}, Item_{i,2}, \dots, Item_{i,N})$.

Алгоритм диференціальної еволюції включає три основні етапи в кожній ітерації: мутація $\rightarrow$ кросингвер $\rightarrow$ відбір.

На початковому етапі формується початкова популяція. Під час етапу мутації на основі вихідної популяції $[Item_{i,it}]$ генерується мутована (донорська) популяція $[Mute_{i,it}]$. Для цього зазвичай використовується рівняння (1), яке визначає процес створення нових рішень.

$$[Mute_{i,it}] = item^{rand1,it} + [MF \times (item^{rand2,it} - item^{rand3,it})], \quad (1)$$

де $rand1, rand2, rand3$ - взаємовиключні, випадково вибрані значення з $[Item_{i,it}]$, MF – фактор мутації, що має додатне значення з інтервалу $[0,2]$.

На наступному етапі, відомому як кросингвер, формується нова пробна популяція $[Probe_{i,it}]$ шляхом комбінування мутантної популяції $[Mute_{i,it}]$ та початкової популяції $[Item_{i,it}]$. Процес кросингверу визначається рівнянням (2):

$$[Probe_{i,it}]_j := \begin{cases} [Mute_{i,it}]_j, & \text{якщо } rand[0,1] < KK \\ [item_{i,it}]_j, & \text{інакше} \end{cases}, \quad (2)$$

де j — індекс особини в популяції, KK — коефіцієнт кросингверу, а $rand$ — випадкове

значення з діапазону $[0,1]$, що забезпечує вибір принаймні одного компонента мутантного вектора в процесі кросингверу. Значення KK також належить інтервалу $[0,1]$.

На завершальному етапі, який називається відбором, проводиться оцінка придатності кожної особини у вихідній популяції $[Item_{i,it}]$ та пробній популяції $[Probe_{i,it}]$. Відбір здійснюється на основі значення функції пристосованості (*fitness function*), яке визначається цільовою функцією. Особина з кращим значенням пристосованості включається до нового покоління популяції. Відбір реалізується згідно з рівнянням (3):

$$[item_{i,it+1}]_j := \begin{cases} [Probe_{i,it}]_j, & \text{якщо } ff(Probe_{i,it}) < ff(item_{i,it+1}) \\ [item_{i,it}]_j, & \text{інакше} \end{cases}, \quad (3)$$

Таким чином, лише особини з вищою пристосованістю залишаються в популяції для наступної ітерації, що сприяє поступовому вдосконаленню рішень.

Після виконання всіх трьох етапів формується нове покоління популяції, яке використовується для подальшої оптимізації. Процес еволюції триває протягом заданої кількості ітерацій або припиняється, коли функція оптимізації досягає заздалегідь встановленого порогового значення.

Цільова функція може містити невизначеність або шум, що впливає на якість отриманих рішень. Наприклад, рівняння (4) може бути використане як цільова функція для оцінки похибки:

$$\Delta_{(R)} = \frac{1}{L} \bigcup_{l=1}^L (fconstr(in_val - \overline{in_val})^2), \quad (4)$$

де $fconstr$ – функція співставлення, in_val – прогнозоване вихідне значення, отримане на основі вхідних параметрів, а $\overline{in_val}$ – фактичне вихідне значення.

Наявність шуму або невизначеності у вхідних даних може бути спричинена похибками вимірювань, нестабільністю системи або іншими непередбачуваними факторами, які не враховувалися під час проектування. Для врахування цих факторів та підвищення стійкості оптимізаційного процесу може бути використана система на основі бази правил впевненості. Розглянемо більш детально опис підходу використання такої системи до обробки невизначеності.

Для цього представимо метод обчислення вихідного значення in_val відповідно до рівняння (4) за допомогою ІСПВ, а також підхід до врахування різних видів невизначеності.

Вихідне значення in_val зазвичай формується на основі нечітких значень, які пов'язані з відповідним ступенем впевненості. Процес виведення результату виконується на основі вхідних даних шляхом обробки правил. Кількість генерованих правил залежить від кількості вхідних змінних.

Кожне правило довіри складається з двох основних компонентів: антецедент (передумова) — містить набір антецедентних атрибутів та консеквент (висновок) — визначає консеквентний атрибут. Антецедентні атрибути представлені у вигляді референтних значень, тоді як ступені впевненості асоціюються з консеквентним атрибутом правила. Загальна формалізація правила впевненості наведена у рівнянні (5):

$$RL_k: \begin{cases} \text{Якщо}(RC_1ref_val_k^1)I/ABO(RC_2ref_val_k^2)I/ABO \Rightarrow \dots I/ABO(RC_{T_k}ref_val_k^{T_k}), \\ \text{ТОДИ}(SC_1, CF_{1k}), (SC_2, CF_{2k}), \dots, (SC_N, CF_{Nk}) \end{cases}, \quad (5)$$

де $CF_{jk} \geq 0, \sum_{j=1}^N CF_{jk} \leq 1$ з вагою правила WR_k і ваговими атрибутами $WA_{k1}, WA_{k2}, \dots, WA_{kT_k}, k \in 1, \dots, L, RC_1, RC_2, \dots, RC_{T_k}$ — антецедентні атрибути k -го правила, $ref_val_k^i (i = 1, \dots, T_k, k = 1, \dots, L)$ — референтні значення антецедентних атрибутів, SC_j — референтне значення консеквентного атрибута, $CF_{jk} (j = 1, \dots, N, k = 1, \dots, L)$ — ступінь впевненості для референтного значення $SC_j, \sum_{j=1}^N CF_{jk} \leq 1$, що визначає, чи є правило повним (якщо рівність виконується) або неповним (якщо нерівність строга), WR_k — вага правила, що визначає його важливість, $WA_{k1}, WA_{k2}, \dots, WA_{kT_k}, k \in 1, \dots, L$ — ваги атрибутів.

Набір правил формує базу правил впевненості. Антецедентні атрибути в правилах можуть бути пов'язані логічними операторами І або АБО, що дозволяє визначати кон'юнктивні або диз'юнктивні припущення. Відповідно, залежно від використовуваної логічної структури, база правил може бути кон'юнктивною або диз'юнктивною.

Після побудови бази правил виконується процедура виведення, яка дозволяє отримати вихідні значення. Вона включає чотири основні етапи:

1. Трансформація вхідних даних — розподіл значень вхідних змінних за референтними значеннями антецедентних атрибутів, що визначає ступінь відповідності.
2. Активізація правил — обчислення ваги активації кожного правила залежно від ступеня відповідності.
3. Оновлення впевненості — коригування ступеня впевненості для кожного правила з урахуванням невизначеності.
4. Агрегація правил — комбінування активованих правил для отримання остаточного вихідного значення за допомогою евідентного підходу до міркування.

Таким чином, ІСПВ дозволяє ефективно обробляти невизначеність у даних, підвищуючи точність моделювання та оптимізаційних розрахунків.

Вага активації w_act_k для k -го правила в кон'юнктивному припущенні обчислюється за

допомогою наступного виразу:

$$w_{act_k} = \frac{WR_k \cap_{i=1}^{T_k} fconstr(rc[r]_i^k)}{\cup_{i=1}^L fconstr(WR_k \cap_{i=1}^{T_k} fconstr(rc[r]_i^k))}, \quad (6)$$

де $fconstr$ – функція співставлення, WR_k – вага правила, $rc[r]_i^k$ – ступінь відповідності k -го правила.

У випадку кон'юнктивного припущення всі ступені відповідності перемножуються, що означає, що активація правила залежить від взаємодії всіх його антецедентних атрибутів.

Однак, для диз'юнктивного припущення вага активації w_{act_k} визначається за допомогою альтернативного виразу:

$$w_{act_k} = \frac{WR_k \cup_{i=1}^{T_k} fconstr(rc[r]_i^k)}{\cup_{i=1}^L WR_k \cup_{i=1}^{T_k} fconstr(rc[r]_i^k)}, \quad (7)$$

Тут, аналогічно, WR_k – це вага правила, а $rc[r]_i^k$ – ступінь відповідності. У диз'юнктивному припущенні ступені відповідності підсумовуються, що дозволяє враховувати частковий вплив окремих антецедентних атрибутів.

Якщо деякі антецедентні атрибути ігноруються, необхідно оновити ступінь впевненості, пов'язаний із кожним правилом. Після цього відбувається агрегація правил, яка здійснюється на основі рекурсивного алгоритму міркування, що визначається рівнянням (8):

$$CF_j = \frac{\theta \times [item - \cap_{k=1}^L fconstr(1 - w_{act_k} \cup_{j=1}^N fconstr(CF_{jk}))]}{1 - \theta \times [\cap_{k=1}^L fconstr(1 - w_{act_k})]}, \quad (8)$$

$$\text{де } item = \cap_{k=1}^L fconstr(w_{act_k} CF_{jk} + 1 - w_{act_k} \cup_{j=1}^N fconstr(CF_{jk}))$$

$$\theta = \left[\bigcup_{j=1}^N \bigcap_{k=1}^L fconstr((w_{act_k} CF_{jk} + 1 - w_{act_k} \bigcup_{j=1}^N fconstr(CF_{jk})) - (N - 1) \right. \\ \left. \times \bigcap_{k=1}^L ((1 - w_{act_k} \bigcup_{j=1}^N fconstr(CF_{jk}))) \right]^{-1}$$

У цих рівняннях: w_{act_k} – вага активації k -го правила, CF_{jk} – це ступінь впевненості, що відповідає одному з консеквентних референтних значень.

Нечіткий вихід після агрегації правил необхідно перетворити у чітке значення. Це виконується шляхом використання значень корисності консеквентного атрибута, що дозволяє отримати остаточний числовий результат:

$$exp_c_i = \sum_{j=1}^N utf(REF_j) CF_j, \quad (9)$$

де exp_c_i – очікуване числове значення, $utf(REF_j)$ – оцінка корисності кожного референтного значення.

Таким чином, ІСПВ дозволяє не тільки враховувати невизначеність у вихідних даних, але й адаптивно коригувати ступінь впевненості, забезпечуючи більш точну оцінку оптимізаційних параметрів.

Здатність системи на основі правил впевненості враховувати різні види невизначеності може бути інтегрована з диференціальною еволюцією для коректного врахування невизначеності цільової функції. Крім того, продуктивність диференціальної еволюції значною мірою залежить від параметрів мутації та кросинговеру. Коефіцієнт мутації (F) та коефіцієнт кросинговеру (KK) можуть бути адаптивно змінені для підвищення ефективності алгоритму диференціальної еволюції. Відомо, що значення F і KK можуть варіюватися на кожній ітерації диференціальної еволюції, що сприяє більш ефективному пошуку оптимальних рішень.

Переважно, при дослідженні диференціальної еволюції, здебільшого розглядаються методи адаптації параметрів на основі значень придатності цільової функції. Проте вони не враховували вплив різних видів невизначеності, пов'язаних із процесом оптимізації. З метою усунення цього недоліку розроблено алгоритм адаптивної диференціальної еволюції на основі ІСПВ. Цей підхід дозволяє ефективно враховувати всі види невизначеності завдяки вбудованим механізмам ІСПВ. Архітектуру системи представлено на рисунку 2.

На кожній ітерації зміни популяції ($item_Change$) та значення цільової функції (FC) кожного індивіда передаються двом модулям: *Модуль F* та *Модуль KK* , які використовують ці значення як вхідні дані (рис. 2). Далі, використовуючи базу правил впевненості та евідентний підхід до міркувань, *Модуль F* та *Модуль KK* обчислюють нові значення параметрів F та KK відповідно для наступної ітерації кожного індивіда популяції.

Зображена на рисунку 2 архітектура являє собою складну адаптивну систему, призначену для оптимізації процесів за допомогою еволюційних алгоритмів, а саме диференціальної еволюції. В її основі лежить принцип зворотного зв'язку, що дозволяє системі динамічно коригувати свої параметри для досягнення оптимальних результатів. Центральним елементом архітектури є блок диференціальної еволюції, який відповідає за генерацію нових популяцій рішень. Диференціальна еволюція, як відомо, є потужним алгоритмом глобальної оптимізації, здатним ефективно досліджувати багатовимірні простори пошуку. Однак його ефективність значною мірою залежить від правильного налаштування

параметрів, таких як коефіцієнти кросингверу (KK) та мутації (F). Така архітектура забезпечує замкнутий цикл зворотного зв'язку, в якому динаміка популяцій та значень придатності використовується для адаптивного налаштування параметрів алгоритму диференціальної еволюції. Це дозволяє системі ефективно реагувати на зміни в просторі пошуку та досягати кращих результатів оптимізації.




Рисунок 2 – Вдосконалена архітектура системи на основі правил з використанням адаптивної диференціальної еволюції

ІСПВ сприяє досягненню оптимального балансу між дослідженням та експлуатацією простору пошуку, визначаючи значення F та KK на основі змін популяції та значень цільової функції на кожній ітерації. Після оновлення значень F та KK виконуються основні оператори диференціальної еволюції: мутація, кросингвер та відбір, у результаті чого формується нова популяція. Процес повторюється до виконання критеріїв зупинки, після чого індивід із найкращим значенням придатності визначається як оптимальне рішення.

Математичне формулювання адаптивної стратегії ІСПВ базується на наступних виразах:

$$\text{item_Change}_i = \bigcup_{j=1}^D f_{\text{constr}}((c_item_{j,i}^g - c_item_{j,i}^{(g-1)})^2; i = 1, \dots, NP; j = 1, \dots, D), \quad (10)$$

$$\text{UTF_Change}_i = (ff_item_i^g - ff_item_i^{(g-1)})^2; i = 1, \dots, NP, \quad (11)$$

де item_Change – це зміна індивіда популяції між двома послідовними ітераціями, $c_item_{j,i}^g$ та $c_item_{j,i}^{(g-1)}$ – координати індивіда на g та $g-1$ ітераціях відповідно. UTF_Change – зміна значення цільової функції $ff_item_i^g$ та $ff_item_i^{(g-1)}$ – відповідні значення функції для індивіда i на ітераціях g та $g-1$.

Для згладжування змін використовується ковзне середнє:

$$\text{mm}[\text{item_Change}]_i = \text{movemean}(\text{item_Change}, \text{tr}), \quad (12)$$

$$\text{mm}[\text{UTF_Change}]_i = \text{movemean}(\text{UTF_Change}, \text{tr}), \quad (13)$$

де movemean – це функція MATLAB для обчислення ковзного середнього зі вікном довжини.

Подальші адаптивні коефіцієнти (ac) визначаються як:

$$[ac_{ij}]_i = 1 - (1 + \text{mm}[\text{item_Change}]_i) e^{-[\text{item_Change}]_i}, \quad (14)$$

$$[ac_{ij+1}]_i = 1 - (1 + \text{mm}[\text{UTF_Change}]_i) e^{-[\text{UTF_Change}]_i}, \quad (15)$$

$$[ac_{i+1j}]_i = 2([ac_{ij}]_i), \quad (16)$$

$$[ac_{i+1j+1}]_i = 2([ac_{i+1j}]_i), \quad (17)$$

Таким чином, запропонований алгоритм дозволяє адаптивно налаштовувати параметри F та KK з урахуванням невизначеностей та динаміки змін у процесі оптимізації, що покращує ефективність та швидкість збіжності алгоритму диференціальної еволюції.

Розраховані значення $[ac_{ij}]_i$ та $[ac_{ij+1}]_i$ використовуються як вхідні параметри *Модуля_KK* для визначення нового значення коефіцієнта кросингверу. Аналогічно, значення $[ac_{i+1j}]_i$ та $[ac_{i+1j+1}]_i$ є вхідними параметрами *Модуля_F*, що відповідають за адаптацію коефіцієнта мутації.

Після другої ітерації значення $[ac_{ij}]_i$, $[ac_{ij+1}]_i$, $[ac_{i+1j}]_i$ та $[ac_{i+1j+1}]_i$ обчислюються згідно з рівняннями (10), (11), (14 - 17) і передаються в *Модуль_KK* та *Модуль_F* для визначення оновлених значень KK та F . Використовуючи ці оновлені параметри, виконуються операції мутації та кросингверу, що генерують нову пробну популяцію. Найкращі особини серед початкової та пробної популяції відбираються для формування нового покоління. Процес триває, доки не буде досягнуто критерію зупинки.

На рисунку 3 наведено дві моделі: *Модуль_KK* для визначення KK та *Модуль_F* для визначення F . Кожен модуль має два антецеденти ($[ac_{ij}]_i$, $[ac_{ij+1}]_i$ для *Модуля_KK* та $[ac_{i+1j}]_i$, $[ac_{i+1j+1}]_i$ для *Модуля_F*) та відповідний консеквентний атрибут. Значення антецедентів нормалізовані у відповідних діапазонах для забезпечення стабільності обчислень.




Рисунок 3 – Моделі використані для визначення KK та F

Система на основі правил впевненості забезпечує ефективне врахування невизначеності в процесі оптимізації, що досягається шляхом її інтеграції з диференціальною еволюцією. Оскільки ефективність диференціальної еволюції значною мірою залежить від параметрів мутації та кросингверу, необхідно адаптивно змінювати коефіцієнти мутації (F) та кросингверу (KK) для покращення пошукової здатності алгоритму. Значення F та KK можуть варіюватися на кожній ітерації, що сприяє ефективнішому знаходженню глобального оптимуму.

Запропонована процедура представляє підхід для обробки невизначеності в цільовій функції через інтеграцію ІСПВ з алгоритмами диференціальної еволюції. ІСПВ здійснює прогнозування значень F та KK на основі змін популяції та значень функції придатності між двома послідовними ітераціями. Прогнозовані параметри F та KK керують процесами мутації та кросингверу в диференціальній еволюції, що сприяє формуванню нової популяції та покращенню навігації в просторі пошуку. Крім того, правила віри визначають прогнозовані значення F та KK таким чином, щоб забезпечити оптимальний баланс між дослідженням (exploration) та експлуатацією (exploitation) простору пошуку. Тепер розглянемо представлений підхід до навчання системи із використанням диференціальної еволюції як оптимальної процедури навчання.

Різні параметри системи, такі як ваги атрибутів (WR_k), ваги правил (WA_i) та ступені впевненості (CF_k), відіграють критичну роль у забезпеченні точності результатів. Ці параметри, які зазвичай визначаються експертами або обираються випадковим чином, впливають на процес адаптації. Антецедентні атрибути та правила віри ранжуються за допомогою ваг атрибутів та ваг правил відповідно. Ступені віри консеквентного атрибута використовуються для представлення невизначеності вихідних даних. Отже, ефективне визначення оптимальних значень цих параметрів є необхідною умовою для підвищення точності ІСПВ. Використовуючи навчальні дані, можна визначити оптимальні параметри системи.

Процес навчання параметрів передбачає мінімізацію різниці між симульованими та спостережуваними вихідними значеннями шляхом оптимізації цільової функції з урахуванням лінійних рівнянь та обмежень нерівності. Вихід ІСПВ представлено у вигляді симульованого значення in_val , тоді як фактичний вихід системи визначається як спостережуване значення $\overline{in_val}$. Різниця між цими значеннями $\Delta_{(R)}$, підлягає мінімізації в процесі оптимізації. Навчальна вибірка містить L точок даних, де $utfl$ є вхідними параметрами для системи, $\overline{in_val}$ – спостережуваним виходом, а in_val ($l = 1, \dots, L$) – симульованим вихідним значенням. Значення похибки визначається згідно з рівнянням (4).

Оптимізація параметрів навчання здійснюється шляхом мінімізації функції помилки:

$$\min_{er} \Delta_{(R)} \quad (18)$$

$$ERR = P(\theta(REF_j), WR_k, WA_k, CF_{ik})$$

де цільова функція навчання системи визначається рівняннями (8) та (9). Для забезпечення коректності правил впевненості сума ступенів впевненості для кожного правила має дорівнювати одиниці. Крім того, значення ваг атрибутів, ваг правил та ступенів віри мають належати інтервалу $[0,1]$. Відповідно, процес оптимізації підпорядковується наступним обмеженням:

- Значення корисності консеквентних атрибутів:

$$\theta(REF_j), j = 1, \dots, n, \theta(REF_i) < \theta(REF_j) n_{pui} < j$$

- Ваги правил:

$$0 \leq WR_k \leq 1, k = 1, \dots, K.$$

- Ваги антецедентних атрибутів:

$$0 \leq WA_k \leq 1, k = 1, \dots, K.$$

Ступені впевненості консеквентного атрибута для k -го правила:

$$0 \leq CF_{jk} \leq 1, j = 1, \dots, n, k = 1, \dots, L.$$

$$\sum_{j=1}^n CF_{jk} = 1.$$

Відповідно, запропонований метод на основі диференціальної еволюції, застосовується для оптимізації параметрів системи. Проте, з метою дотримання обмежень системи, рівняння (3) було модифіковано шляхом додавання штрафної функції, що враховано у рівнянні (19). Такий підхід гарантує, що особи популяції, які не задовольняють встановленим обмеженням, отримуватимуть нижчі значення функції придатності.

$$[item_{i,it+1}]_j := \begin{cases} [Pr o be_{i,it}]_j, & \text{якщо } ff(Pr o be_{i,it}) + pf(Pr o be_{i,it}) < ff(item_{i,it}) + PF(item_{i,i}) \\ (item_{i,it}) & \text{інакше} \end{cases} \quad (19)$$

На початковому етапі всі параметри навчання та структура системи ініціалізуються. Далі відбувається оптимізація параметрів за допомогою запропонованого алгоритму з використанням диференціальної еволюції, який генерує оптимальні значення параметрів навчання для початкової структури системи. Оновлена база правил адаптується на основі оптимізованих параметрів, після чого перевіряється критерій зупинки. Оскільки для першої ітерації цей критерій не виконується, алгоритм переходить до оптимізації структури.



Рисунок 4 – Алгоритмічна схема механізму роботи ІСПВ з використанням підходу диференціальної еволюції

Оптимізація структури системи здійснюється з використанням стратегічного евристичного алгоритму (SOHS - Self-Organizing Neuristic Strategy), який призначений для адаптивної оптимізації структури ІСПВ у процесі навчання, щоб покращити точність і стабільність моделі. Після цього повторно виконується оптимізація параметрів навчання відповідно до оновленої структури. Процес ітеративно повторюється до тих пір, поки структура залишається незмінною протягом заданої кількості ітерацій. Загальний механізм навчання на основі ІСПВ з використанням диференціальної еволюції у контексті спільної оптимізації представлений у вигляді блок-схеми на рисунку 4.

Даний алгоритм призначений для оптимізації бази правил впевненості як за параметрами, так і за її структурою. Процес починається з введення початкової бази правил, яка використовується як основа для подальших обчислень. На першому етапі алгоритм виконує оптимізацію параметрів навчання з використанням методу диференціальної еволюції. Після цього отримані оптимізовані параметри використовуються для оновлення бази правил, покращуючи її ефективність. Далі здійснюється перевірка критерію зупинки, який визначає, чи досягнуто бажаного рівня якості бази. Якщо критерій виконується, процес завершується, і отримується оптимізована база правил. Якщо ж критерій не виконано, алгоритм переходить до наступного етапу – оптимізації структури бази правил за допомогою SOHS алгоритму. Після оновлення структури бази правил процес повторюється, починаючи з повторної оптимізації параметрів навчання. Цикл триває доти, доки база правил не буде оптимізована як за параметрами, так і за структурою. Таким чином, алгоритм поетапно покращує базу правил впевненості, використовуючи комбінований підхід оптимізації параметрів і структури, що забезпечує високу якість моделі.

Таким чином, представлений підхід реалізує оптимальний процес навчання для ІСПВ, що базується на концепції спільної оптимізації, де підхід диференціальної еволюції застосовується для оптимізації параметрів, а SOHS використовується як метод удосконалення структури.

Висновки

У цьому дослідженні запропоновано оптимальну процедуру оптимізації яка інтегрує концепцію інтелектуальних систем на основі правил впевненості із диференціальною еволюцією для врахування невизначеності цільової функції. Представлена методологія також виконує прогнозування оптимальних значень керуючих параметрів на основі підходу диференціальної еволюції, сприяючи ефективному балансу між розширенням і звуженням простору пошуку рішення. Запропоновано механізм навчання для систем на основі правил, що базується на спільній оптимізації, де підхід диференціальної еволюції використовується для оптимізації параметрів, а стратегічний евристичний алгоритм – для оптимізації структури еко-системи.

Подальші напрями роботи будуть зосереджені на дослідженні питань нейромережевої інтеграції запропонованої методології.

Література

1. Sumathi, S., & Kumar, L. A. (2018). Computational intelligence paradigms for optimization problems using MATLAB®/SIMULINK®. CRC Press. Haktanirlar Ulutas, B., Kulturel-Konak, S. A review of clonal selection algorithm and its applications. *Artif Intell Rev* 36, 117–138 (2011). <https://doi.org/10.1007/s10462-011-9206-1>
2. Walczak, B., & Marini, F. (2015). Particle swarm optimization (PSO). A tutorial. *Chemometrics and Intelligent Laboratory Systems*, 149.
3. Das, S., & Suganthan, P. N. (2010). Differential evolution: A survey of the state-of-the-art. *IEEE transactions on evolutionary computation*, 15(1), 4-31.
4. Pant, M., Zaheer, H., Garcia-Hernandez, L., & Abraham, A. (2020). Differential Evolution: A review of more than two decades of research. *Engineering Applications of Artificial Intelligence*, 90, 103479.
5. Liu, J., & Lampinen, J. (2005). A fuzzy adaptive differential evolution algorithm. *Soft Computing*, 9, 448-462.
6. Chamorro, H. R., Riano, I., Gerndt, R., Zelinka, I., Gonzalez-Longatt, F., & Sood, V. K. (2019). Synthetic inertia control based on fuzzy adaptive differential evolution. *International Journal of Electrical Power & Energy Systems*, 105, 803-813.
7. Yu, W. J., Li, J. J., Zhang, J., & Wan, M. (2014, July). Differential evolution using mutation strategy with adaptive greediness degree control. In *Proceedings of the 2014 Annual Conference on Genetic and Evolutionary Computation* (pp. 73-80).
8. Zhang, J., & Sanderson, A. C. (2009). JADE: adaptive differential evolution with optional external archive. *IEEE Transactions on evolutionary computation*, 13(5), 945-958.