

Сльота Максим Русланович

студент

Національний технічний університет України «Київський політехнічний інститут»

Сльота Максим Русланович

студент

Национальный технический университет Украины «Киевский политехнический институт»

Maksym Slyota

Student

National Technical University of Ukraine «Kyiv Polytechnic Institute»

**ЗАСТОСУВАННЯ МЕТОДІВ ШТУЧНОГО ІНТЕЛЕКТУ
ДЛЯ РОЗВ'ЯЗАННЯ СИСТЕМНИХ ЗАДАЧ РОЗПІЗНАВАННЯ
КРИТИЧНИХ СИТУАЦІЙ**

**ПРИМЕНЕНИЕ МЕТОДОВ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА
ДЛЯ РЕШЕНИЯ СИСТЕМНЫХ ЗАДАЧ РАСПОЗНАВАНИЯ
КРИТИЧЕСКИХ СИТУАЦИЙ**

**APPLICATION OF ARTIFICIAL INTELLIGENCE
METHODS FOR SOLVING SYSTEM PROBLEMS
OF CRITICAL SITUATIONS RECOGNITION**

Анотація. В роботі досліджена ефективність застосування класичних методів штучного інтелекту для розв'язання системних задач класифікації та розпізнавання небезпечних ситуацій.

Ключові слова: системний аналіз, штучний інтелект, небезпечні ситуації.

Аннотация. В работе исследована эффективность применения классических методов искусственного интеллекта для решения системных задач классификации и распознавания опасных ситуаций.

Ключевые слова: системный анализ, искусственный интеллект, опасные ситуации.

Abstract. This paper investigated the effectiveness of the classical methods of artificial intelligence to solve system problems of classification and identification of danger situations.

Keywords: systems analysis, artificial intelligence, danger situation.

Вступ

На практиці часто виникає необхідність дослідження системних задач розпізнавання і запобігання критичним ситуаціям у складних системах різного призначення. Враховуючи тенденції та особливості розвитку сучасної техніки такі задачі стають особливо актуальними. Адже від вчасного виявлення та класифікації небезпечних ситуацій, залежить не тільки надійність функціонування окремих функціональних елементів, а складної системи в цілому. Ключовою проблемою виявлення таких ситуацій є стабільне інформаційне забезпечення особи, що приймає рішення (ОПР). Вирішення таких задач вимагає системного підходу і є предметом дослідження даної роботи.

Для формування ефективної методології з достатнім арсеналом методів та алгоритмів необхідно розглянути відомі методи, які успішно застосовуються для вирішення класичних математичних задач, проаналізувати ефективність відомих методів для розв'язання специфічних задач системного аналізу та визначити шляхи їх модифікації.

Математична модель задачі класифікації образів

Зважаючи на побудову загальної теоретичної частини та математичної моделі системних проблем [1], визначимо ключові особливості під час постановки задачі розпізнавання та класифікації ситуацій. В загальному випадку задачі розпізнавання критичних ситуацій, є схожими до звичайних задач розпізнавання




Рисунок 1. Основні елементи побудови системи розпізнавання образів

образів, що включають в себе множину математичних методів класифікації та кластеризації. Адже кожна ситуація із множини об’єктів розпізнавання, як і образ, може бути класифікована за визначеним набором ознак до певного класу. Основною метою є побудова такого правила (функціоналу), який з мінімально можливою похибкою класифікуватиме об’єкти спостереження [2].

Загальна схема системи розпізнавання образів показана на Рис. 1. Задача полягає в співвіднесенні вихідного образу x одному з класів ω_i . Правила співвіднесення образу одного з класів називаються класифікатором і реалізуються в блоці класифікації. Якщо образам відповідають вектори — елементи метричного простору, то співвідношення образу класу можна здійснити, наприклад, за допомогою обчислення відстані між вектором і класом. На виході класифікатора ми повинні отримати той клас (номер клас) в якому належить вхідний образ з зазначенням ступеня достовірності класифікації або отримати інформацію про те, що вхідний образ не належить жодному з класів [3].

У загальній моделі розпізнавання може бути блок навчання. Цей блок за вибіркою так званих навчальних образів, які належать членам класу, дозволяє сформулювати правила класифікації в тій або іншій формі. Крім цього, за навчальним образам можуть бути вироблені правила вибору найбільш інформативних ознак.

Нехай U — множина ознак в даній задачі розпізнавання. Окремий образ з цієї множини будемо позначати за x . Кожен образ $x \in U$ може характеризуватися нескінченною (і навіть незліченною) кількістю ознак. На етапі формування алфавіту ознак ми повинні вибрати деяку підмножину ознак (як правило, кінцеву), яку називаються простором ознак. Цю множину будемо позначати через X . Як правило, множина X забезпечена лінійними або метричними структурами. Найчастіше X — скінченновимірний метричний $X = \mathbb{R}^N$ або лінійний простір. Нехай x — елемент простору X , що відповідає образу $x \in U$, а $P: U \rightarrow X$ — оператор, що відображає x в x . Зауважимо, що оператор P є оператором проектування, тобто $P^2 = P$. Крім того, $X = P(U)$.

Припустимо, що в множині образів U в даній задачі розпізнавання нас цікавлять деякі підмножини —

класи. У класичній задачі класифікації вважається, що множина класів

$$\Omega = \{\omega_1, \dots, \omega_m\} \tag{1}$$

являється скінченною, і класи утворюють повну групу підмножин з U (розбиття простору образів U), тобто

$$\bigcup_{i=1}^m \omega_i = U, \omega_i \cap \omega_j = \emptyset, \forall i \neq j. \tag{2}$$

В загальному випадку класів може бути і нескінченно багато і вони можуть не утворювати повну групу множин. Задачу класифікації в цьому випадку називають узагальненою [4].

Класифікувати образ $x \in U$ по класам $\{\omega_1, \dots, \omega_m\}$ — це значить знайти так звану індикаторну функцію

$$g: U \rightarrow Y, Y = \{y_1, \dots, y_m\} \tag{3}$$

яка ставить у відповідність образу $x \in U$ мітку $y_i \in Y$ того класу ω_i , якому він належить, тобто $g(x) = y_i$, якщо $x \in \omega_i$.

Реально ми маємо справу не з усією множиною образів U , а тільки з проекцією $X = P(U)$ — простором ознак. Тоді потрібно знайти таку функцію $g: X \rightarrow Y$, яка ставила б у відповідність кожному вектору $x = Px \in X$ мітку $y_i \in Y$ того класу ω_i , якому належить відповідний образ, тобто $g(x) = y_i$ якщо $x = Px, x \in \omega_i$ така функція називається вирішальною [3].

Зауважимо, що множина $P^{-1}x, x \in X$ може не бути одно-елементною, тому воно може мати непусті перетини з різними класами ω_i . Як наслідок, функція $g(x)$ буде неоднозначною. Відповідно до загальних підходів розв’язання задач з багатозначної функції $g(x)$ можна виділити однозначну гілку, щоб вона задовольняла певним умовам оптимальності. В якості такого критерію оптимальності може виступати мінімізації помилки неправильної класифікації.

У просторі ознак X множині класів $\Omega = \{\omega_1, \dots, \omega_m\}$ (1) відповідає деякий, взагалі кажучи, покриття $\widetilde{X}_1, \dots, \widetilde{X}_m$, простору X :

$$\widetilde{X}_i = \{x = Px : x \in \omega_i\}, i = 1 \dots m \tag{4}$$

Множини $\widetilde{X}_1, \dots, \widetilde{X}_m$, можуть взагалі кажучи, перетинатися. Тому замість покриття $\widetilde{X}_1, \dots, \widetilde{X}_m$ розглядатимемо розбиття X_1, \dots, X_m простору X таке, що $X_i \subseteq \widetilde{X}_i$. Таке розбиття буде визначатися

неоднозначно. Чим «правильніше» виділені найбільш інформативні ознаки, тим «ступінь неоднозначності» вибору розбиття X_1, \dots, X_m буде меншим. Області X_i будемо називати областями переваги класів $\tilde{\omega}_i$. Як правило, на етапі навчання системі розпізнавання доступна інформація про класи у вигляді деякої множини пар (x_j, y_j) , $j=1..N$, де

$$x_j = Px_j, y_j = g(x_j) \in Y. \quad (5)$$

Множина $\Xi = \{x_1, \dots, x_N\}$ називають навчальною вибіркою, а пару (x_j, y_j) – прецедентом. По множині прецедентів

$$(\Xi, Y) = \{(x_j, y_j) : j=1, \dots, N\} \quad (6)$$

потрібно знайти вирішальне правило – функцію $g(x)$, яка здійснювала б класифікацію елементів навчальної вибірки з найменшим числом помилок.

Особливості системних задач розпізнавання критичних ситуацій

Проте в межах системного підходу виникають додаткові умови, які не враховуються в звичайних задачах розпізнавання образів. Серед них виділимо найбільш суттєві.

1. В першу чергу необхідно враховувати той факт, що аналіз якісних характеристик інформації вимагає розробку методів перетворення цих характеристик у числові еквіваленти. Ці методи мають бути інтегровані у загальну математичну модель.

2. Аналіз якісних характеристик інформації суттєво залежить від предметної області, а тому кожна прикладна задача буде по-своєму унікальною і вимагатиме індивідуального підходу під час її формалізації.

3. В процесі аналізу та класифікації ніколи не можна гарантувати повноту вхідної інформації.

4. Формування якісних характеристик інформації найчастіше має нечіткий характер.

5. Значно ускладнює процес класифікації ситуацій принципова необмеженість простору ознак розпізнавання.

6. Системний підхід вимагає врахування факторів ризику, що неодмінно впливають на систему в процесі її функціонування.

7. Складність оцінювання похибок побудованих моделей через відсутність чітких критеріїв оцінки критичності ситуацій. Тому для вирішення таких задач доцільно використовувати набір методів і визначити рівень узгодженості їх результатів.

Таким чином ми визначили роль та місце задач розпізнавання критичних ситуацій в процесі функціонування складних технічних та інформаційних систем. Сформулювали основні вимоги до побудови ефективної методології для визначення рівня небез-

пеки та її розпізнавання. Далі розглянемо модель класифікації та розпізнавання образів, що була застосована для вирішення системної задачі та проаналізуємо її сумісність з інформаційною платформою системного підходу.

Опис моделі розпізнавання

Для реалізації моделі розпізнавання ситуацій в інформаційному аналізі було обрано нечітку нейронну мережу, структура якої зображена на рис. 2.

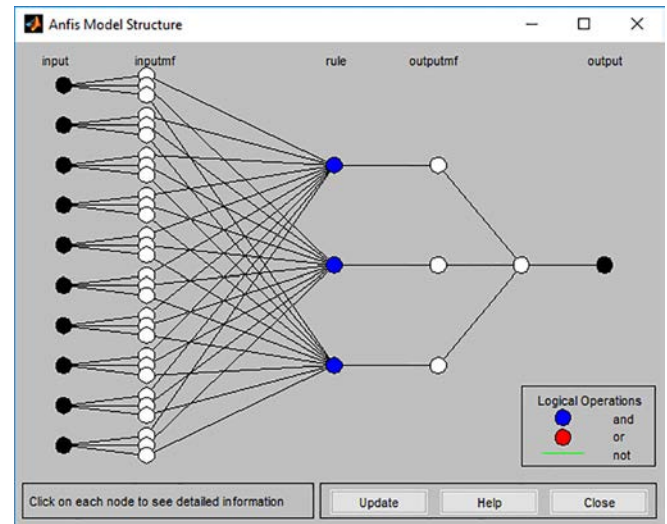


Рисунок 2. Структура нейронної мережі

Нечітка нейронна мережа, побудована на основі мережі ANFIS. Така нейронна мережа дозволяє враховувати нечіткість вхідної інформації та застосувати нечіткі алгоритми класифікації. Детальніше розглянемо особливості побудови нейронної мережі.

ANFIS (Adaptive-Network-Based Fuzzy Inference System) – адаптивна мережа нечіткого виведення. ANFIS це один із варіантів гібридних нейро-нечітких мереж прямого поширення похибки особливого типу. Архітектура нейро-нечіткої мережі ізоморфна нечіткій базі знань. У нечітких нейронних мережах використовуються операції множення та імовірнісне OR, а також гладкі функції належності – трикутні, дзвоноподібні та гаусові. Це дозволяє застосовувати для налаштування нечітких нейронних мереж швидкі алгоритми навчання, засновані на методі зворотного поширення помилки.

Розглянемо особливості функціонування кожного із шарів мережі (рис. 2).

Перший шар – терми вхідних змінних. Кожен вузол першого шару представляє один терм із дзвоноподібною функцією належності (7). Входи мережі з'єднані тільки зі своїми термами. Виходом вузла є ступінь належності значення вхідної змінної відповідного нечіткому терму.

$$\mu_r(x_i) = \frac{1}{1 + \left(\frac{x_i - c}{a}\right)^{2b}} \tag{7}$$

Другий шар – посилки нечітких правил. Кожен вузол цього шару відповідає одному нечіткому правилу. Вузол другого шару з’єднаний з тими вузлами першого шару, які формують посилки відповідного правила. Отже, кожен вузол другого шару може приймати від 1 до *n* вхідних сигналів. Виходом вузла є ступінь виконання правила, яка розраховується як добуток вхідних сигналів. Вихід кожного вузла позначимо через τ_r .

Третій шар – Нормалізація ступенів виконання правил. Кожен вузол цього шару розраховує відносну ступінь виконання нечіткого правила:

$$\tau_r^* = \frac{\tau_r}{\sum_{j=1}^m \tau_j}$$

Четвертий шар – укладення правил. Кожен вузол з’єднаний з одним вузлом третього шару, а також з усіма входами мережі. Вузол четвертого шару розраховує внесок одного нечіткого правила в вихід мережі.

$$y_r = \sum_{i=0}^n b_{ir} x_i$$

П’ятий шар – агрегування результату, отриманого за різними правилами. Єдиний вузол цього шару підсумовує вклади всіх правил.

Описана нечітка нейронна мережа була застосована для розв’язання системної задачі прогнозування технічного стану автомобіля за показниками датчиків. На вході мали 10 різних показників: витрати палива (л/км), поточна швидкість (км/год), споживча потужність системи забезпечення автомобіля (Вт), напруга бортової мережі (В), напруга акумуляторів (В), показники тертя тормозних колодок (кН), відсоток викидів вуглекислого газу у відсотках, показники датчика тиску на впускному газовідводі (Па), показники лямбда-зонду (%), показники датчика корисного ходу (%).

Аналіз результатів

Задача, запропонована для перевірки якості моделі розпізнавання критичних ситуацій, дає можливість сформуванню навчальної вибірки. Тому теоретично, можна застосовувати класичні методи машинного навчання для її розв’язання. Хоча в процесі розв’язання багатьох системних задач, спостерігається відсутність даних про досліджуваний об’єкт і, як наслідок, відсутність даних для навчання. В таких випадках можна використовувати моделі само організаційних нейронних мереж.

Для визначення небезпеки ситуації були використані наступні критерії

- $\omega_1 : y < 1$ – безпечна ситуація
- $\omega_2 : y \in [1; 2)$ – критична ситуація
- $\omega_3 : y \in [2; 3)$ – надзвичайна ситуація
- $\omega_4 : y \in [3; 4)$ – аварійна ситуація
- $\omega_5 : y \geq 4$ – катастрофічна ситуація

Навчальні вибірка містила дані показників датчиків автомобіля в фіксовані моменти часу. Дискретизація даних дорівнювала ~ 10 хв. В фіксовані моменти часу автомобіль піддавався деяким деструктивним факторам, які відображалися на показниках датчиків, а тому запропонована модель мала би відповідно реагувати на такі впливи і змінювати клас небезпеки поточної ситуації.

Проте зважаючи на принципові обмеження побудови нейронних мереж, для класифікації ситуацій, були введені спрощення які будуть описані далі. І це значно вплинуло на результати роботи. На рис. 3 позначений результат класифікації.

Значення нормованої похибки розраховувалося за формулою

$$e = \sum_{i=1}^n \frac{(x_i - \min x_i)}{\max x_i - \min x_i}$$

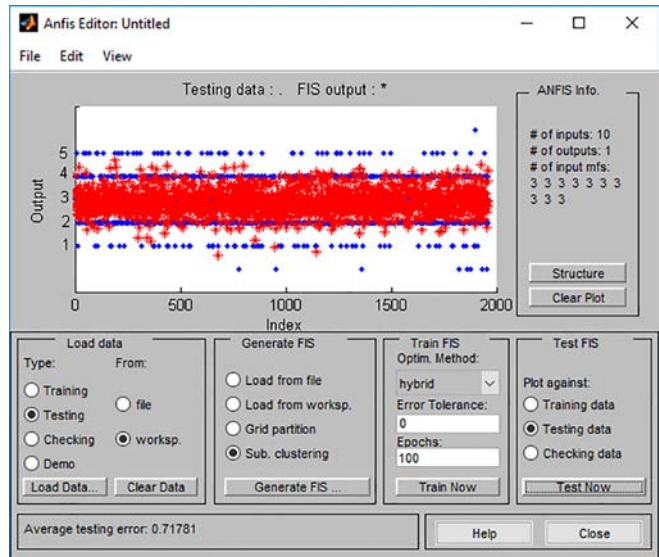


Рисунок 3. Результати розпізнавання

На рис. 4 зображений графік похибок розпізнавання.




Рисунок 4. Графік помилок в залежності від розміру вибірки

Як бачимо, класифікація ситуацій в запропонованій системній задачі має похибку 0,7181.

Хоча застосування цієї моделі для прогнозування значень окремих компонентів (показників датчиків) в середньому давали хороші результати. Нормоване значення похибки дорівнювало 0,1027.

Аналізуючи результати, варто зазначити про деякі спрощення, які були застосовані в запропонованій моделі.

По-перше, дана модель принципово не може враховувати фактори ризику, які, відповідно до системного підходу, варто включати в математичну модель. Вважатимемо, що автомобіль в процесі функціонування піддається впливу випадкових руйнівних факторів, які враховуються в експлуатаційний період деталей та гарантійний термін. Тому цими параметрами можна знехтувати. Хоча, як бачимо, знехтування показниками факторів ризику та відсутність модуля їх розпізнавання, частково впливає на результати класифікації.

По-друге, множина ознак, для класифікації, була обмеженою (3 терми). Хоча в загальному випадку простір ознак ситуації необмежений, а тому треба динамічно змінювати множину ознак класифікації в процесі функціонування складної системи.

По-третє, вихідний параметр нечіткої мережі $y \in R$. Хоча множина класів безпеки є скінченною, а тому перетворення вихідних величин, створює додаткову похибку прогнозування.

Виходячи із особливостей інформаційної платформи задач інформаційного аналізу найбільш суттєвими вимогами, які висуваються до методів, які можуть за-

стосовуватися для задач класифікації та розпізнавання критичних ситуацій є:

1. Врахування нечіткості та неповноти вхідної інформації.

2. Орієнтація на обробку великої кількості даних в режимі онлайн.

3. Швидкодія методів для забезпечення вчасного формування результатів роботи.

4. Відсутність стандартної навчальної вибірки у вигляді скінченного набору даних про ознаки кожного класу прийнятої класифікації, що визначається принциповою необмеженістю простору ознак.

Тому класичні методи машинного навчання не можуть бути застосовані для розв'язання системних задач класифікації та розпізнавання рівня небезпеки ситуацій без застосування додаткових модулів обробки нечітких даних, врахування випадкових зовнішніх, по відношенню системи факторів впливу тощо. Для побудови якісних моделей, варто застосовувати комплексні підходи з залученням експертних моделей, для ефективного застосування математичних методів в умовах відсутності повної інформації про досліджуваний об'єкт.

Висновки. Таким чином, в результаті проведеного дослідження, була побудована модель класифікації ситуацій для розв'язання системних задач, на основі нечіткої нейронної мережі ANFIS. Аналіз якості моделі показав, що класичні методи машинного навчання погано адаптовані для розв'язання системних задач, а тому мають бути суттєво модифіковані, пристосовані до специфічної інформаційної платформи та використовуватися у комплексі з експертними моделями.

Література

1. Згуровський М.З., Панкратова Н.Д. Основи системного аналізу / Сергієнко В.І, Кунцевич В.М. — К.: Видавнича група ВНУ, 2007, — 544 с.
2. Курс лекцій «Штучні нейронні мережі» [Електронний ресурс]. — Режим доступу: victoria.lviv.ua/html/neural_nets/zmist.htm
3. Курс лекцій «Математичні методи розпізнавання образів» [Електронний ресурс]. — Режим доступу: <http://www.ccas.ru/frc/papers/mestetskii04course.pdf>
4. Rumelhart D. E. Learning internal representations by error propagation. In Parallel distributed processing / Rumelhart D. E., Hinton G. E., Williams R. // Data Science Guide — 1986. — Vol. 1 — pp. 310–328.