

к.т.н. Самойлов І.В. (ВІТІ)
 д.т.н. Чевардін В.Є. (ВІТІ)
 к.т.н. Застело Г.І. (ВІТІ)
 к.т.н. Мазулевський О.Є. (ВІТІ)

ЗАСТОСУВАННЯ ІНТЕЛЕКТУАЛЬНИХ ТЕХНОЛОГІЙ ДЛЯ НАСТРОЙКИ НЕЧІТКИХ ВІДНОШЕНЬ В СИСТЕМАХ ДІАГНОСТИКИ

На сьогодні актуальною проблемою є створення систем діагностування, які можуть опрацювати нечітку діагностичну інформацію. Нечітка модель діагностики будується на основі композиційного правила виведення Заде, в якому носієм діагностичної інформації є матриця нечітких відношень „причини–наслідки”, що зв’язує вектор мір значимості причин і вектор мір значимості наслідків. Побудова моделі здійснюється в два етапи. На першому етапі (структурна ідентифікація) здійснюється формування і груба настройка моделі шляхом побудови бази знань за доступною експертною інформацією або за експериментальними даними. На другому етапі (параметрична ідентифікація) реалізується тонка настройка нечіткої моделі.

У статті запропоновано двофазну тонку настройку параметрів моделі на базі нечітких відношень. На першій off-line фазі використовується наявна навчальна вибірка і генетичний алгоритм для грубого влучення в область глобального мінімуму між модельними і експериментальними результатами. На другій on-line фазі використовується нейро-нечітка мережа для підстройки параметрів моделі і їх адаптивної корекції по мірі появи нових експериментальних даних. Особливість даного підходу полягає в тому, що структура розв’язку на етапі генетичної настройки і на етапі нейронної підстройки відрізняється. Зокрема, кількість параметрів навчання на етапі генетичної оптимізації є меншою, ніж на етапі нейронної підстройки, що дозволяє зменшити область пошуку розв’язку і відповідно час його отримання. При цьому формування розв’язку здійснюється послідовно, по мірі переходу від одного наслідку до іншого.

Ключові слова: генетичний алгоритм, нейронна мережа, нечіткі відношення, тонка настройка, нечіткі множини, інтервальна функція належності.

Самойлов И.В., Чевардин В.Э., Застело Г.И., Мазулевский О.Э. Использование интеллектуальных технологий для настройки нечетких отношений в системах диагностики. На сегодня актуальной проблемой является создание систем диагностирования, которые могут обрабатывать нечеткую диагностическую информацию. Нечеткая модель диагностики строится на основе композиционного правила вывода Заде, в котором носителем диагностической информации является матрица нечетких отношений "причины-следствия", связывающей вектор мер значимости причин и вектор мер значимости последствий. Построение модели осуществляется в два этапа. На первом этапе (структурная идентификация) осуществляется формирование и грубая настройка модели путем построения базы знаний по доступной экспертной информации или экспериментальными данными. На втором этапе (параметрическая идентификация) реализуется тонкая настройка нечеткой модели.

В статье предлагается двухфазная тонкая настройка параметров модели на базе нечетких отношений. На первой off-line фазе используется имеющаяся обучающая выборка и генетический алгоритм для грубого попадания в область глобального минимума между модельными и экспериментальными результатами. На второй on-line фазе используется нейро-нечеткая сеть для подстройки параметров модели и их адаптивной коррекции по мере появления новых экспериментальных данных. Особенность данного подхода заключается в том, что структура решения на этапе генетической настройки и на этапе нейронной подстройки отличается. В частности, количество параметров обучения на этапе генетической оптимизации меньше, чем на этапе нейронной подстройки, что позволяет уменьшить область поиска решений и соответственно время его получения. При этом формирование решения осуществляется последовательно, по мере перехода от одного следствия к другому.

Ключевые слова: генетический алгоритм, нейронная сеть, нечеткие отношения, тонкая настройка, нечеткие множества, интервальная функция принадлежности.

I. Samoylov, V. Chevardin, H. Zastelo, O. Mazulevsky Application of Intelligent Technologies for Adjusting Fuzzy Relations in Diagnostic Systems. One of the current problems is the creation of diagnostic systems that can process fuzzy diagnostic information. The fuzzy diagnostic model is based on Zadeh's compositional rule, where the matrix of the fuzzy cause-effect relationship is the carrier of diagnostic information, which connects the vector of causes' significance measurements and the vector of consequences' significance measurements. The construction of the model is carried out in two stages. In the first stage (structural identification) the formation and rough tuning of the model is realized by building a knowledge base according to some available expert information or experimental data. In the second stage (parametric identification), fine-tuning of the fuzzy model is fulfilled.

The article introduces a two-phase fine-tuning of model parameters based on fuzzy relationships. During the first off-line phase a training sample and a genetic algorithm are utilized to roughly include the global minimum between the model and experimental results. During the second on-line phase a neuro-fuzzy network is implemented to

adjust model parameters and adaptively correct them as new experimental data emerge. The peculiarity of this approach is that the solution structures at the stage of genetic tuning and at the stage of neural tuning are different. In particular, the number of training options at the genetic optimization stage is smaller than at the neural tuning stage, which reduces the search area and therefore the time at which it is obtained. In this case, the solution formation is done sequentially, as we move from one consequence to another.

Keywords: genetic algorithm, neural network, fuzzy relationships, fine tuning, fuzzy sets, interval membership function.

Постановка завдання. На сьогодні актуальною науково-технічною проблемою є створення систем діагностування, які можуть опрацьовувати нечітку діагностичну інформацію. У базах знань таких систем міститься не тільки кількісна інформація, що характеризує стан об'єкта діагностики, а і якісна інформація, яка являє собою експертні оцінки. Для формалізації експертної інформації при моделюванні причинно-наслідкових зв'язків зручно використовувати теорію нечітких множин [1]. Нечітка модель діагностики будується на основі композиційного правила виведення Заде [2], в якому носієм діагностичної інформації є матриця нечітких відношень „причини-наслідки”, що зв'язує вектор мір значимості причин і вектор мір значимості наслідків.

Аналіз останніх публікацій. Побудова моделі здійснюється в два етапи, які за аналогією з класичними методами [3, 4] можна вважати етапами структурної і параметричної ідентифікації. Перший етап є традиційний для технології нечітких експертних систем [5]. На ньому здійснюється формування і груба настройка моделі шляхом побудови бази знань за доступною експертною інформацією або за експериментальними даними. Чим вищий професійний рівень експерта, тим вище адекватність нечіткої моделі, побудованої на першому етапі. Однак, не можна гарантувати збігу результатів нечіткого логічного виведення і експериментальних даних. Тому необхідний другий етап, на якому здійснюється тонка настройка нечіткої моделі шляхом її навчання за експериментальними даними.

На другому етапі реалізується тонка настройка нечіткої моделі. Етап тонкої настройки зведений до задачі нелінійної оптимізації, для розв'язання якої в [6] використовується генетичний алгоритм. Недоліком методу є те, що генетичний алгоритм погано пристосований для врахування нових даних, що надходять в навчальну вибірку. В роботі [7] був запропонований метод нейро-лінгвістичної ідентифікації нелінійних залежностей. Лінгвістична інформація про об'єкт діагностики представляється у вигляді спеціальної нейро-нечіткої мережі, ізоморфної нечіткої бази знань. Для навчання мережі використовуються рекурентні співвідношення, отримані на основі градієнтного методу. Принциповою перевагою цього методу є можливість навчання нечітких баз знань, в реальному масштабі часу, тобто в режимі on-line. Недоліком методу є можливість влучення в локальний екстремум.

Мета роботи. Запропонувати двофазну тонку настройку параметрів моделі на базі нечітких відношень. На першій off-line фазі використовувати наявну навчальну вибірку і генетичний алгоритм для грубого влучення в область глобального мінімуму нев'язки між модельними і експериментальними результатами. На другій on-line фазі використовувати нейро-нечітку мережу для підстройки параметрів моделі і їх адаптивної корекції по мірі появи нових експериментальних даних. Особливість даного підходу полягає в тому, що структура розв'язку на етапі генетичної настройки і на етапі нейронної підстройки відрізняється. Зокрема, кількість параметрів навчання на етапі генетичної оптимізації є меншою, ніж на етапі нейронної підстройки, що дозволяє зменшити область пошуку розв'язку і відповідно час його отримання. При цьому формування розв'язку здійснюється послідовно, по мірі переходу від одного наслідку до іншого.

Виклад основного матеріалу. Нехай навчальна вибірка задана у вигляді M пар експериментальних даних:

$$\langle \hat{X}_p, \hat{Y}_p \rangle, p = \overline{1, M},$$

де $\widehat{X}_p = \left(\widehat{x}_1^p, \widehat{x}_2^p, \dots, \widehat{x}_n^p \right)$ – вектор значень вхідних змінних в експерименті номер p ;

$\widehat{Y}_p = \left(\widehat{y}_1^p, \widehat{y}_2^p, \dots, \widehat{y}_m^p \right)$ – вектор значень вихідних змінних в експерименті номер p .

Припустимо, що $s_j, j = \overline{1, m}$, – деякий наслідок, який розглядається як лінгвістичний терм. Нечітка множина, за допомогою якої формалізується терм s_j , являє собою сукупність

пар: $S_j = \left\{ \frac{\mu_1^{s_j}}{d_1}, \frac{\mu_2^{s_j}}{d_2}, \dots, \frac{\mu_n^{s_j}}{d_n} \right\}$, де $\{d_1, d_2, \dots, d_n\} = D$ – універсальна множина причин;

$\mu_i^{s_j}$ – ступінь належності елемента $d_i \in D, i = \overline{1, n}$ нечіткій множині s_j [8].

Нехай $Q = \left(q_1, q_2, \dots, q_m \right)$ – вектор параметрів концентрації нечітких множин наслідків S_j такий, що матриця нечітких відношень має вигляд:

$$R = \begin{bmatrix} \left(r_{11} \right)^{q_1} & \left(r_{12} \right)^{q_2} & \dots & \left(r_{1m} \right)^{q_m} \\ \left(r_{21} \right)^{q_1} & \left(r_{22} \right)^{q_2} & \dots & \left(r_{2m} \right)^{q_m} \\ \dots & \dots & \dots & \dots \\ \left(r_{n1} \right)^{q_1} & \left(r_{n2} \right)^{q_2} & \dots & \left(r_{nm} \right)^{q_m} \end{bmatrix}. \quad (1)$$

З урахуванням матриці (1) співвідношення, яке визначає залежність „причини–наслідки” для нечіткої моделі діагностики можна записати в такому вигляді:

$$Y = f \left(X, C_X, P_D, Q_R, P_S \right), \quad (2)$$

де X – множина вхідних змінних; Y – множина вихідних змінних; $P_D = \left(G_D, C_D \right)$ – вектори параметрів функцій належності вхідних змінних до нечітких термів причин; $P_S = \left(G_S, C_S \right)$ – вектори параметрів функцій належності вихідних змінних до нечітких термів наслідків; C_X – вектор параметрів концентрації функцій належності, що моделюють неточність вхідних змінних.

Задача тонкої настройки нечітких відношень може бути сформульована так: необхідно підібрати такі вектори параметрів функцій належності вхідних і вихідних змінних, вектор параметрів концентрації нечітких множин наслідків та вектори параметрів концентрації функцій належності, що моделюють неточність вхідних даних, які забезпечують мінімальну відстань між теоретичними і експериментальними виходами об’єкта:

$$\sum_{p=1}^M \left[\sum_{j=1}^m \left[f_j \left(\widehat{X}_p, C_X, P_D, Q_R, P_S \right) - \widehat{y}_j^p \right]^2 \right] = \min_{C_X, P_D, Q_R, P_S}. \quad (3)$$

Етапи навчання нечітких відношень наведені в табл. 1. З табл. 1 видно, що на першому етапі за допомогою генетичного алгоритму здійснюється пошук грубого розв’язку задачі (3). На етапі генетичної оптимізації визначаються координати максимуму функцій належності

нечітких термів, а параметри концентрації вважаються відомими. На другому етапі за допомогою нейронної мережі здійснюється уточнення розв'язку задачі (3). У випадку наявності вхідних даних з відомим середнім відхиленням до вектора параметрів навчання додається вектор параметрів концентрації функцій належності, що моделюють неточність вхідних даних C_X . Тому на цьому етапі шляхом нейронної підстройки здійснюється уточнення розв'язку задачі (3) на базі раніше отриманого розв'язку.

Таблиця 1

Етапи настройки нечітких відношень

Модель	Параметри навчання			Кількість параметрів навчання	Метод
	Вхідні змінні	Вихідні змінні	Нечіткі відношення		
Точні вхідні дані	G_D	G_S	Q_R	$n + m$	Генетичний алгоритм
	G_D, C_D	G_S, C_S	Q_R	$2n + 3m$	Нейронна мережа
Неточні вхідні дані	G_D, C_D, C_X	G_S, C_S	Q_R	$3n + 3m$	

Генетичний алгоритм. Якщо визначати параметри функцій належності нечітких термів причин і наслідків одночасно, це призведе до пошуку в безперспективних областях і додаткових витрат часу. Тому при реалізації генетичного алгоритму пропонується формувати розв'язок по мірі переходу від одного наслідку (рівняння) до наступного. В даному випадку наближений розв'язок системи рівнянь нечітких відношень може бути отриманий шляхом розв'язання послідовності систем нечітких рівнянь спрощеного вигляду. Такий підхід відтворює міркування експерта, який в процесі прийняття рішення послідовно оцінює внесок кожної причини, поступово аналізуючи наслідки. На практиці експерт починає аналізувати наявний стан об'єкта з того наслідку, який має найбільшу вагу і є вирішальним для діагностики конкретної причини. Для визначення початкових значень параметрів концентрації нечітких множин наслідків може бути використаний метод парних порівнянь Сааті [8], на основі якого можуть бути побудовані матриці парних порівнянь наслідків. При реалізації генетичного алгоритму розв'язання задачі оптимізації (3) модель (2) розглядається як сукупність моделей спрощеного вигляду:

$$y_1 = f_1 \left(X, C_X, G_D, C_D, Q_1, G_S^1, C_S^1 \right); \quad (4)$$

$$y_1 = f_1 \left(X, C_X, G_D, C_D, Q_2, G_S^2, C_S^2 \right);$$

$$y_2 = f_2 \left(X, C_X, G_D, C_D, Q_2, G_S^2, C_S^2 \right); \quad (5)$$

$$\dots \quad \dots \quad \dots$$

$$y_1 = f_1 \left(X, C_X, G_D, C_D, Q_j, G_S^j, C_S^j \right);$$

$$y_2 = f_2 \left(X, C_X, G_D, C_D, Q_j, G_S^j, C_S^j \right);$$

$$\dots$$

$$y_j = f_j \left(X, C_X, G_D, C_D, Q_j, G_S^j, C_S^j \right); \quad (6)$$

де $Q_j = (q_1, q_2, \dots, q_j)$, $G_S^j = (g^{S_1}, g^{S_2}, \dots, g^{S_j})$, $C_S^j = (c^{S_1}, c^{S_2}, \dots, c^{S_j})$ – вектори параметрів функцій належності нечітких термів наслідків на j -му етапі генетичного алгоритму.

Тоді задача навчання нечіткої моделі (3) зводиться до розв'язання послідовності задач

$$\sum_{p=1}^M \left[f_1 \left(\hat{X}_p, G_D, Q_1, G_S^1 \right) - \hat{y}_j^p \right]^2 = \min_{G_D, Q_1, G_S^1}; \quad (7)$$

$$\sum_{p=1}^M \left[\sum_{j=1}^2 \left[f_j \left(\hat{X}_p, G_D, Q_2, G_S^2 \right) - \hat{y}_j^p \right]^2 \right] = \min_{G_D, Q_2, G_S^2}; \quad (8)$$

$$\dots$$

$$\sum_{p=1}^M \left[\sum_{j=1}^J \left[f_j \left(\hat{X}_p, G_D, Q_J, G_S^J \right) - \hat{y}_j^p \right]^2 \right] = \min_{G_D, Q_J, G_S^J}. \quad (9)$$

Структура алгоритму знаходження грубого розв'язку має вигляд:

```

begin
  for  $j = 1$  to  $m$  do {перехід від одного наслідку до іншого}
    begin
      Знайти вектори  $G_D, G_S^j$ ;
      Уточнити значення параметрів векторів  $G_D^{j-1}$ ;
    end;
  end.
  
```

Спочатку на основі розв'язку задачі (7) здійснюється настройка елементів першого стовпця матриці нечітких відношень, тобто параметрів функцій належності G_S^1 та параметрів функцій належності вхідних змінних G_D .

Потім на основі розв'язку задачі (8) здійснюється настройка елементів першого і другого стовпця матриці нечітких відношень, тобто параметрів функцій належності нечітких термів наслідків G_S^2 . При цьому здійснюється уточнення параметрів функцій належності нечітких термів причин G_D , отриманих в результаті настройки моделі (4).

Аналогічно із розв'язку задачі (9) здійснюється настройка елементів 1, 2, ..., j стовпців матриці нечітких відношень, тобто параметрів функцій належності нечітких термів наслідків G_S^j . При цьому здійснюється уточнення параметрів функцій належності нечітких термів причин G_D , отриманих в результаті настройки моделі (5).

Для реалізації генетичного алгоритму розв'язання задач (7) – (9) необхідно визначити основні поняття і операції. *Хромосому* визначимо як рядок, що змінюється при переході від моделі (4) до моделі (6) (рис. 1). Для розв'язання задачі (7) хромосома містить двійкові коди векторів G_D, Q_1, G_S^1 , для задачі (8) – коди векторів G_D, Q_2, G_S^2 , для задачі (9) – коди векторів G_D, Q_j, G_S^j .




Рис. 1. Структура хромосоми на j -му етапі генетичного алгоритму

Операція *схрещування* визначена на рис. 2. Вона полягає в обміні частин хромосом в кожному з векторів G_D, Q_j, G_S^j параметрів функцій належності нечітких термів причин і наслідків. Точки схрещування, показані пунктиром, вибираються випадковим чином.




Рис. 2. Структура операції схрещування

Мутація (Mu) передбачає випадкову зміну елементів хромосоми:

$$\begin{aligned}
 Mu(g^{d_i}) &= RANDOM\left(\left[\begin{array}{c} x_i \\ \bar{x}_i \end{array}\right]\right); & Mu(g^{s_j}) &= RANDOM\left(\left[\begin{array}{c} y_j \\ \bar{y}_j \end{array}\right]\right); \\
 Mu(q_j) &= RANDOM\left(\left[0, 1\right]\right). & &
 \end{aligned}
 \tag{10}$$

Відбір хромосом-батьків для операції схрещування повинний здійснюватись не випадково. Для цього використовувалась процедура відбору, що дає пріоритет кращим розв'язкам. Чим більша функція відповідності деякої хромосоми, тим більша повинна бути імовірність того, що дана хромосома дасть потомство [1]. В якості функції відповідності вибираються критерії (7) – (9)

$$FF_1 = -f_1, FF_2 = -f_2, \dots, FF_j = -f_j,$$

тобто чим вища ступінь пристосованості хромосоми до виконання критерію оптимізації, тим більша функція відповідності. При виконанні генетичного алгоритму розмір популяції залишається постійним. Тому після операції схрещування і мутації з отриманої популяції необхідно видалити хромосоми, що мають гірші значення функції відповідності.

Нехай $P(t)$ – хромосоми-батьки, а $C(t)$ – хромосоми-нащадки на t -й ітерації. Загальна структура генетичного алгоритму має вигляд:

begin

$t = 0$; Задати початкову множину $P(t)$;

Оцінити функцію відповідності на основі критеріїв (7) – (9);

while (немає умови завершення) **do**

Породжувати $C(t)$ шляхом схрещування $P(t)$;

Виконати мутацію $C(t)$ за формулами (10);
 Оцінити $C(t)$ за допомогою критеріїв (7) – (9);
 Вибрати $P(t+1)$ з $P(t)$ і $C(t)$;
 $t := t + 1$;

end

end.

Нейро-нечітка мережа. Розглянемо спосіб представлення лінгвістичної інформації про об'єкт діагностики у вигляді спеціальної нейро-нечіткої мережі, ізоморфної рівнянням нечітких відношень. Структура нейро-нечіткої мережі представлена на рис. 3, а зміст вузлів показаний в табл. 2.




Рис. 3. Структура нейро-нечіткої мережі

Нейро-нечітка модель на рис. 3 отримана шляхом імплантації матриці нечітких відношень в нейронну мережу таким чином, що вагами дуг, які підлягають настроюванню, є нечіткі відношення. З рис. 3 видно, що нейро-нечітка мережа має п'ять шарів: шар 1 – входи об'єкта; шар 2 (3) – нечіткі терми причин μ^{d_i} , $i = \overline{1, n}$, або їх комбінація; шар 4 – нечіткі терми наслідків μ^{s_j} , $j = \overline{1, m}$; шар 5 – операція дефазифікації, тобто перетворення результатів нечіткого логічного виведення в чітке число.

Число вузлів в нейро-нечіткій мережі визначається так: шар 1 – за кількістю входів об'єкта; шар 2 (3) – за кількістю нечітких термів причин; шар 4 – за кількістю нечітких термів наслідків; шар 5 – за кількістю вихідних змінних.

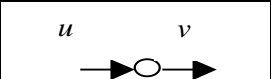
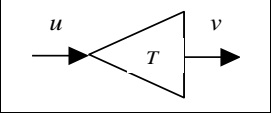
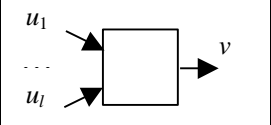
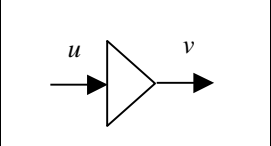
Дуги графа на рис. 3 зважені таким чином: функція належності вхідної змінної до нечіткого терму причини – дуги між 2-м і 3-м шарами; нечіткими відношеннями – дуги між 3-м і 4-м шарами; функція належності вихідної змінної до нечіткого терму наслідку – дуги між 4-м і 5-м шарами.

Суть навчання полягає в підборі таких ваг дуг (параметрів функцій належності нечітких термів причин і наслідків, параметрів концентрації нечітких множин наслідків), які мінімізують різницю між теоретичними і експериментальними виходами об'єкта.

Таблиця 2

Елементи нейро-нечіткої мережі

Вузол	Назва	Функція
-------	-------	---------

	Вхід	$v = u$
	Нечіткий терм причини	$v = \mu^T(u)$ $v = \sup[\min(\mu^*(u), \mu^T(u))]$
	Нечіткий терм наслідку	$v = \mu^{S_j} \max_{i=1, n}(u_i)$
	Дефазифікація	$v = \frac{\sum_{k=1}^N y_j^k u(y_j^k)}{\sum_{k=1}^N u(y_j^k)}$

Розглянемо задачу оптимізації (3). В цьому випадку для навчання параметрів моделі F використовується система рекурентних співвідношень:

$$\begin{aligned}
 q_j(t+1) &= q_j(t) - \eta_q \frac{\partial E_t}{\partial q_j(t)}; \\
 g^{d_i}(t+1) &= g^{d_i}(t) - \eta_g \frac{\partial E_t}{\partial g^{d_i}(t)}; & c^{d_i}(t+1) &= c^{d_i}(t) - \eta_c \frac{\partial E_t}{\partial c^{d_i}(t)}; \\
 g^{s_j}(t+1) &= g^{s_j}(t) - \eta_g \frac{\partial E_t}{\partial g^{s_j}(t)}; & c^{s_j}(t+1) &= c^{s_j}(t) - \eta_c \frac{\partial E_t}{\partial c^{s_j}(t)}, \quad (11)
 \end{aligned}$$

які мінімізують критерій $E_t = \frac{1}{2} (f_j(t) - \hat{y}_j(t))^2$, що використовується в теорії нейронних мереж, де $f_j(t)$, $\hat{y}_j(t)$ – теоретичний і експериментальний виходи об’єкта діагностики на t -ому кроці навчання; $q_j(t)$ – параметр концентрації нечіткої множини наслідку на t -ому кроці навчання; $g^{d_i}(t)$, $c^{d_i}(t)$ – параметри функцій належності вхідних змінних до нечітких термів причин на t -ому кроці навчання; $g^{s_j}(t)$, $c^{s_j}(t)$ – параметри функцій належності вихідних змінних до нечітких термів наслідків на t -ому кроці навчання; η_g , η_c , η_q – параметри навчання.

Якщо враховувати неточність вхідних даних, то до системи рекурентних співвідношень (11) слід додати співвідношення: $c_i^*(t+1) = c_i^*(t) - \eta_c \frac{\partial E_t}{\partial c_i^*(t)}$, де $c_i^*(t)$ – параметр концентрації функцій належності вхідних змінних на t -ому кроці навчання.

Аналогічно правилу „back-propagation”, алгоритм навчання нейро-нечіткої мережі складається з двох фаз. На першій фазі обчислюються модельні значення виходів об’єкта діагностики (f_1, f_2, \dots, f_m), що відповідають заданій архітектурі мережі. На другій фазі обчислюється значення нев’язки (E_t) і перераховуються ваги міжнейронних зв’язків (11).

Розглянемо *приклад* діагностики причин незадовільної роботи прикладного програмного забезпечення в мережі Ethernet. До основних причин незадовільної роботи мережі можливо віднести наступні несправності: d_1 – дефект серверів або робочих станцій; d_2 – дефект мережних плат; d_3 – дефект концентраторів, повторювачів та трансіверів; d_4 – кабельне середовище, тощо.

Перелічені причини несправностей мають вплив на такі контрольні параметри мережі: (діапазони змін вказані в дужках): s_1 – утилізація каналу зв'язку (19 – 82 %); s_2 – кількість конфліктів в мережі (1 – 5 %); s_3 – довжина пакета (64 – 1518 байт); s_4 – час обігу чи прослуховування (10 – 150 мкс). Наслідками, що спостерігаються є: зниження s_1 , s_3 або підвищення s_1 , s_2 , s_3 , s_4 відповідно.

Для настройки нечіткої моделі використовувались результати тестування 40 локальних мереж з різними типами несправності. Навчальна вибірка формувалась у вигляді пар „вектор параметрів наслідків – вектор причин”.

Результати розв'язання задачі оптимізації (3) генетико-нейронним методом представлені в табл. 3. З таблиці видно, що на етапі генетичної оптимізації параметри концентрації функцій належності не змінювались, при цьому визначались тільки координати максимуму, а на етапі нейронної настройки параметри концентрації функцій належності зменшились, а координати максимуму практично не змінились.

Таблиця 3

Параметри функцій належності нечітких термів наслідків

Модель	Параметри	Нечіткі терми				Етап
		s_1	s_2	s_3	s_4	
Точні вхідні дані	G_S	30	3	512	65	Генетичний алгоритм
	C_S	0,5	0,5	0,5	0,5	
	G_S	32	3,5	496	58	Нейро- нечітка мережа
	C_S	0,4	0,35	0,32	0,3	
	Q_R	0,92	0,97	1,00	0,87	

Змінення нечітких відношень в ході двоетапної настройки представлено у вигляді такої матриці:

$$R = \begin{array}{c} \begin{array}{cccc} & s_1 & s_2 & s_3 & s_4 \\ d_1 & 0,48 / 0,50 & 0,63 / 0,67 & 0,37 / 0,45 & 0,36 / 0,64 \\ d_2 & 0,33 / 0,28 & 0,72 / 0,85 & 0,87 / 0,82 & 0,25 / 0,20 \\ d_3 & 0,78 / 0,84 & 0,42 / 0,38 & 0,65 / 0,74 & 0,68 / 0,58 \\ d_4 & 0,69 / 0,75 & 0,47 / 0,67 & 0,28 / 0,35 & 0,85 / 0,91 \end{array} \end{array}$$

Значення в чисельнику відповідають нечітким відношенням, які отримані на першому (грубому) етапі настройки в результаті використання генетичного алгоритму, значення в знаменнику уточнювались в результаті навчання нейро-нечіткої мережі (другий етап).

Показники ефективності етапів настройки нечітких відношень наведені в табл. 4. З таблиці видно, що найкращі результати діагностування забезпечуються для причин d_1 та d_3 , найменш точний діагноз для причин d_2 та d_4 .

Значення критерію оптимізації (3) після етапу генетичної настройки становить 3,07, а після етапу нейронної настройки – 0,84. При цьому передбачалось, що дані, які використовувались для настройки, є точними.

Нехай експериментальні дані спотворені шумом з відхиленням $\sigma = \pm 3\%$. В результаті розв'язання задачі (3) для неточних вхідних даних параметри функцій належності нечітких термів причин та наслідків практично не змінились.

Параметр концентрації функцій належності, що моделюють неточність вхідних значень, становить 0,003.

В цьому випадку значення критерію оптимізації (3) після етапу генетичної оптимізації становить 3,54, а після нейронної підстройки – 1,04.

Показники ефективності настройки нечітких відношень			Генетична настройка	Нейронна настройка
Ймовірність правильного діагнозу за типами розв'язків	d_1		8 / 10 = 0,8	9 / 10 = 0,9
	d_2		4 / 10 = 0,4	6 / 10 = 0,6
	d_3		7 / 10 = 0,7	8 / 10 = 0,8
	d_4		5 / 10 = 0,5	6 / 10 = 0,6
Критерій оптимізації	Точні дані		3,07	0,84
	$\sigma = \pm 3 \%$		3,54	1,04
Час настройки			28 хв.	2 хв.
Кількість ітерацій			12000	300

З таблиці видно, що використання точних функцій належності для настройки нечіткої моделі при неточних даних не може забезпечити прийнятної точності діагностики. Застосування функцій належності, що моделюють неточність вхідних даних, дозволило лише незначно покращити значення критерію оптимізації (3). В той же час послідовно використання генетичного алгоритму та нейронної мережі дозволило зменшити час настройки нечітких відношень при надходженні нових експериментальних даних.

Висновок. Таким чином, для тонкої настройки нечітких відношень пропонується використовувати генетико-нейронний метод. Генетичний алгоритм використовувати для грубого, але швидкого формування розв'язку по мірі переходу від одного наслідку до наступного. Нейронну мережу використовувати для уточнення розв'язку і його адаптивної корекції по мірі надходження нових експериментальних даних. Крім того нейро-мережевий підхід забезпечує адаптацію параметрів моделі до варіації вхідних даних, що зумовлені неточністю результатів вимірювань.

Напрямок подальших досліджень є удосконалення послідовного методу настройки нечіткої моделі, що дозволить зменшити середній час настройки та оцінити вплив невизначеності на точність діагностики.

ЛІТЕРАТУРА

1. Ротштейн А.П. Интеллектуальные технологии идентификации: нечеткие множества, генетические алгоритмы, нейронные сети. – Винница: УНІВЕРСУМ-Вінниця, 1999. – 320 с.
2. Заде Л. Понятие лингвистической переменной и её применение к принятию приближенных решений. – М.: Мир, 1976. – 167 с.
3. Тэрано Т., Асаи К., Сугэно М. Прикладные нечеткие системы. – М.: Мир, 1993. – 280 с.
4. Штейнберг Ш.Е. Идентификация в системах управления. – М.: Энергоатомиздат, 1987. – 81 с.
5. Архангельский В.И., Богаенко И.Н., Грабовский Г.Г., Рюмшин Н.А. Системы функци-управления. – К.: Техніка, 1997. – 208 с.
6. Митюшкин Ю. И., Мокин Б. И., Ротштейн А. П. Soft Computing: идентификация закономерностей нечеткими базами знаний / МОН Украины. – Винница: УНІВЕРСУМ-Вінницяю – 2002. – 145 с.
7. Ротштейн А.П., Митюшкин Ю.И. Нейро-лингвистическая идентификация нелинейных зависимостей // Кибернетика и системный анализ. – 2000. – № 2. – С. 179–180.
8. Самойлов І.В. Експертний метод побудови нечітких відношень на базі парних порівнянь для систем діагностики // Збірник наукових праць ВІТІ ДУТ – 2014. – № 1. – С. 74 – 78.