

## Розділ 3

## ГІБРИДНА МОДЕЛЬ УПРАВЛІННЯ ІНДИВІДУАЛІЗОВАНИМ НАВЧАННЯМ

### Основні поняття і терміни

- |  |   |
|--|---|
| <ul style="list-style-type: none"> <li>– <i>Нейромережева модель синергетичного управління</i></li> <li>– <i>Визначення виду дидактичної системи</i></li> <li>– <i>Нейро-нечітка модель</i></li> <li>– <i>Асоціативний механізм міжпредметних зв'язків</i></li> <li>– <i>Нейронна мережа Хопфілда</i></li> <li>– <i>Нечітка кластеризація</i></li> <li>– <i>Субтрактивна кластеризація</i></li> <li>– <i>Кластерний аналіз матриці формування компетенцій</i></li> </ul> | <ul style="list-style-type: none"> <li>– <i>Гомогенні групи осіб, що навчаються</i></li> <li>– <i>Навчання шару Кохонена</i></li> <li>– <i>Еволюційна модель вибору</i></li> <li>– <i>Ієрархічна система нечіткого логічного висновку</i></li> <li>– <i>Визначення ступеня сформованості системи компетенцій</i></li> </ul> |
|--|---|

### 3.1 Нейромережева реалізація синергетичної моделі управління

Декомпозиція структурно-функціональної схеми СУН обумовила особливість її реалізації на основі синтезу перетворювачів інформації щодо основних параметрів управління. Наскрізним для усього процесу навчання є реалізація синергетичної моделі управління. Тому розглянемо особливості її реалізації.

Так як теорія синергетичного управління є сучасною концепцією синтезу та аналізу систем управління багатомірними нелінійними об'єктами у динамічних системах, а одним з універсальних засобів формування управляючих впливів є нейронні мережі, то перспективним є об'єднання концепцій синергетичного та нейромережевого управління в динамічних системах [1].

Основною метою нейромережевої реалізації є відтворення на виході навченої нейронної мережі параметру управління. Апроксимацію нелінійних безперервних функцій можна виконати за допомогою двошарової нейромережі. Для того, щоб сконструювати алгоритм навчання нейромережі, яка забезпечить належну якість процесу на виході, на основі поєднання динамічних процесів управління нелінійним об'єктом і налагодження багатошарової мережі, доцільно використати стандартний алгоритм зворотного розповсюдження помилки, підбираючи функцію узагальненої похибки навчання  $\sigma$ . В загальному випадку синтез структури і алгоритмів навчання містить вибір архітектури мережі, функціоналу навчання і мети управління, складання розширеної системи диференціальних рівнянь, вибір узагальненої похибки  $\sigma$  навчання й синтез алгоритму управління.

На основі співвідношень (2.4) – (2.6) можна визначити, що управління навчанням у вигляді оптимального співвідношення між знаннями та вміннями для кожного учня визначається п'ятьма параметрами:  $f, c, x, y, \lambda$ . Тому в якості елементів вхідного шару розглянемо ці п'ять змінних. Структура трьохшарової нейронної мережі наведено на рис. 3.1.




Рисунок 3.1 - Структура нейронної мережі синергетичного управління навчанням

При визначенні кількості нейронів проміжного шару було використано евристичне правило [2], на основі якого ця кількість становить половину сумарної кількості входів та виходів. Функцією активації обрано гіперболічну тангенціальну. В якості функції навчання обрано функцію, що

реалізує метод зворотного розповсюдження (алгоритм Левенберга-Марквардта), яка забезпечує максимальну швидкодію.

Існує велика кількість програмних продуктів, які реалізують нейромережеву архітектуру. Простим та доступним є пакет Neural Networks Toolbox (нейронні мережі) математичної системи Matlab, розробленої фірмою MathWorks. В склад пакету входить спеціальна функція NEWFF для створення багат шарових нейронних мереж прямої передачі з заданими функціями навчання й налагодження, які використовують метод зворотного розповсюдження помилки [2]. Розглянемо на прикладі використання даної функції для реалізації нейромережевого управління синергетичною моделлю навчання.

Як відомо, функція `newff` призначена для створення багат шарових нейронних мереж прямого передавання сигналу з заданими функціями навчання та налагодження, які використовують метод зворотного розповсюдження помилки. Функція `net` формує багат шарову нейронну мережу, має наступний синтаксис [2]:

$$net = newff(PR, [S1 S2 \dots SN], [TF1 TF2 \dots TFN], btf, blf, pf), \quad (3.1)$$

де вхідні аргументи:

$PR$  - масив розміру  $R \times 2$  мінімальних та максимальних значень для  $R$  векторів входу;

$S_i$  - кількість нейронів в шарі  $i$ ;

$TF_i$  - функція активації шару  $i$ ; за умовчанням - `tan sig`;

$btf$  - функція навчання, що реалізує метод зворотного розповсюдження, за умовчанням `trainlm`;

$blf$  - функція налагодження, яка реалізує метод зворотного розповсюдження, за умовчанням `learnqdm`;

$pf$  - критерій якості навчання, за умовчанням `mse`;

вихідні аргументи:

*net* - об'єкт класу `network object` багатошарової нейронної мережі.

За алгоритм навчання обрано алгоритм LM Левенберга-Марквардта [3], який реалізує наступну стратегію для оцінок матриці Гессе [4]. За припущенням, що функціонал визначається як сума квадратів похибок, що є характерним при навчанні нейронних мереж з прямою передачею, гессіан може бути наближено обчислено як:

$$H \cong J^T J, \quad (3.2)$$

а градієнт обчислюється за формулою:

$$g = J^T e, \quad (3.3)$$

де  $J = \frac{\partial J}{\partial W}$  - матриця Якобі похідних функціонала похибки за налагодженим параметрам;  $e$  - вектор похибок мережі. Матриця Якобі може бути обчисленою на основі стандартного методу зворотного розповсюдження похибки, що суттєво просте обчислення матриці Гессе.

Алгоритм LM використовує апроксимацію гессіана наступного вигляду:

$$x_{k+1} = x_k - \left( J^T J + \mu I \right)^{-1} J^T e_k. \quad (3.4)$$

Якщо коефіцієнт  $\mu$  дорівнює 0, то отримуємо метод Ньютона з наближенням гессіана у формі (3.2); якщо значення  $\mu$  велике, то отримуємо метод градієнтного спуску з маленьким кроком. Оскільки метод Ньютона має більшу точність та швидкість сходження біля мінімуму задача полягає в тому, щоб в процесі мінімізації як можна швидше перейти до метода Ньютона. З цією метою параметр  $\mu$  зменшують після кожної успішної ітерації та збільшують тільки тоді, коли пробний крок показує збільшення функціоналу похибки. Така стратегія забезпечує зменшення похибки після кожної ітерації алгоритму. Функція `trainlm` реалізує алгоритм LM Левенберга-Марквардта в системі Matlab, характеризується наступними параметрами, що задаються за умовчанням:

```
net.trainParam
```

```
ans=
```

```

epochs:      100
goal:        0
max_fail:    5
mem_reduc:   1
min_grad:    1.0000e-010
mu:          0.0010
mu_dec:      0.1000
mu_inc:      10
mu_max:      1.0000e+010
show:        25
time:        Inf

```

Параметр  $\mu$  – це початкове значення коефіцієнту  $\mu$ . Це значення помножується або на коефіцієнт  $\mu\_dec$ , якщо функціонал похибки зменшується, або на коефіцієнт  $\mu\_inc$  – якщо функціонал похибки збільшується. У випадку, коли  $\mu$  перевищує значення  $\mu\_max$ , алгоритм зупиняється. Параметр  $mem\_reduc$  дозволяє економити об'єм потрібної пам'яті.

Для зменшення розмірності в наведеному прикладі обмежимо розгляд двома векторами параметрів моделей осіб, що навчаються. Вхідні данні для моделювання та навчання багатошарової нейромережі наведено в таблиці 3.1.

Таблиця 3.1 Вхідні данні

	P					T
	c	f	x	y	$\lambda$	
1	0,1	0,2	0,3	20	50	0,3
2	0,2	0,3	0,4	25	30	0,4

До вхідних аргументів функції `newff` відносяться: масив входу P, строки якого являють собою різні варіанти значень параметрів моделі учня  $f, c, x, y, \lambda$ , які отримано на основі опитування експертів; вектор цілей T;

інформація щодо структури шарів мережі; мінімальні й максимальні значення для R векторів входу. Задаємо наступні навчаючі послідовності:

```
P=[0.1 0.2; 0.2 0.3; 0.3 0.4; 20 25; 50 30];
```

```
T=[0.3 0.4];
```

Архітектура нейронної мережі: трьохшарова мережа з прямою передачею сигналу; перший шар – 5 нейронів, другий (схований) шар – 3 нейрони; вихідний шар – 1 нейрон. Функції активації першого та другого шарів – сигмоїдальна нелінійна функція гіперболічного тангенсу `tansig`, третього шару – лінійна тотожна `purelin`. Тоді формування багатшарової нейронної мережі має вигляд:

```
net=newff([0 1; 0 1; 0 1; 20 80; 0 100], [5 3 1], {'tansig','tansig','purelin'},  
'trainlm');
```

```
gensim(net);
```

Виконаємо моделювання мережі, визначимо вектор виходу Y для кожного з варіантів вхідних даних та побудуємо графік виводу (рис.3.2.):

```
Y=sim(net,P);
```

```
plot(T,Y)
```

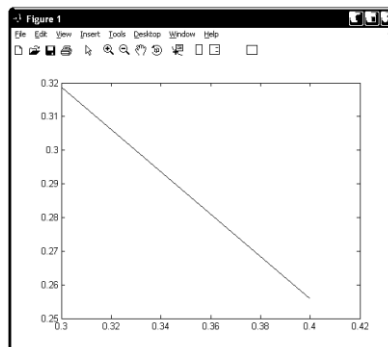


Рисунок 3.2 - Графік відповідності виходу й цілі

Навчимо мережу на протязі 50 циклів (рис.3.3):

```
net.trainParam.epochs = 50;
```

```
net=train(net,P,T);
```

Характеристика точності навчання показано на рис.3.3, усталена середньоквадратична похибка складає приблизно  $7,7 \cdot 10^{-33}$ .




Рисунок 3.3 - Графік навчання нейронної мережі

Виконаємо моделювання сформованої трьохшарової мережі із використанням навчаючої послідовності входу:

$Y = \text{sim}(\text{net}, P);$

$\text{plot}(T, Y);$

Результати моделювання наведено на рис.3.4, де верхня лінія відповідає співвідношенню між виходами й цілями після навчання, а верхня – до навчання, свідчить про добре відображення вхідної послідовності у вихідну.

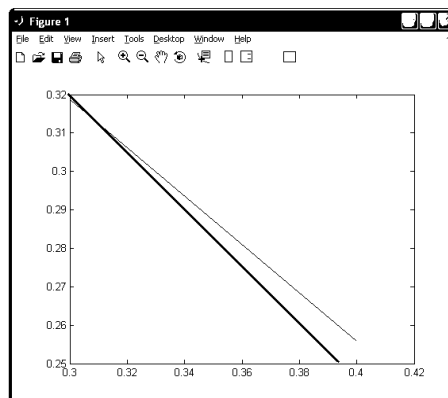


Рисунок 3.4 - Графіки відповідності виходу й цілі до та після навчання

Таким чином, виконано формування й навчання нейронної мережі, на основі якої можна отримувати значення частки часу, що доцільно відвести накопиченню знань, що відповідає визначенню співвідношення між формуванням знань та вмій для кожного конкретного учня. Особливістю запропонованої схеми є використання синергетичного підходу, що базується на урахуванні внутрішнього розвитку об'єкту (вектору інтелекту учня) при виборі навчаючих впливів.

### **3.2. Нейро-нечітка модель визначення виду дидактичної системи (ДС)**

Проектування технології навчання полягає в постановці дидактичної задачі (ДЗ) та формуванні дидактичної системи, тобто системи методів, засобів та форм навчання, які адекватні умовам та закономірностям учіння. З восьми відомих, згідно сучасній класифікації [5], [6], найбільш ефективною є система адаптивного програмного навчання. Така система здійснює циклічне спрямоване автоматичне управління навчанням. Основу функціонування даної системи складає спеціальна адаптивна програма, що керує навчальною діяльністю особи, що навчається. Система повинна здійснювати спрямований інформаційний процес, вирішуючи задачі адаптації процесу навчання до основних параметрів моделі учня. Вдосконалення інформаційного процесу в бік індивідуалізації не тільки за темпом, а й по змісту, призводить до поширення моно дидактичних систем до дванадцяти за рахунок додавання систем дистанційного навчання трансляційного, кореспондентного типів, системи дистанційного навчання з адаптивною навігацією, системи штучного інтелекту [7]. США забезпечують замкнуте управління пізнавальною діяльністю, яке індивідуалізоване за темпом та змістом на основі автоматизації засобів управління. Однак, на практиці монодидактичні системи застосовуються рідко. Звичайно навчальний процес будується таким чином, що синтезується певна полідидактична система, використання якої здійснює управління пізнавальною діяльністю учнів. При цьому, у відповідності з властивістю емерджентності, комбінована система може отримати властивості, які перевищують якості систем, з що входять до неї.

Зазвичай в схемах управління навчанням в якості об'єкта управління розглядається учень, або його модель [8]. Однак, аналіз закономірностей навчання показує, що можливості підвищення якості навчання знаходяться в строгій залежності від ДС, що застосовується. У зв'язку із практичною неоглядністю кількості комбінованих систем, а також у зв'язку із необхідністю постійного супроводу процесу навчання адаптаційними



процесами щодо вибору оптимальної дидактичної системи, їх проектування потребує від викладача високого рівня професіоналізму та значних часових та інтелектуальних витрат. Тому вважаємо за доцільне дослідити можливість використання інтелектуальних технологій для автоматизації формування управляючого впливу у вигляді визначення доцільної ДС для поточної педагогічної ситуації в процесі навчання.

Для формування структурно-параметричної моделі ДС визначимо основну мету функціонування ДС, сукупність елементів, що її складають, параметри взаємозв'язків між ними. Дидактичну систему утворюють методи, форми та засоби навчання. В автоматизованому навчанні діяльність викладача з вибору раціональних методів, форм та засобів навчання реалізується у вигляді змісту, структури, алгоритму функціонування комп'ютерних засобів навчання. Для формалізованого опису процесу створення ДС, розглянемо макромодель процесу навчання (рис.3.5).




Рисунок 3.5 - Макромодель процесу навчання

Педагогічна система (ПС)  $Sp$  є перетворювачем стану середовища  $X$  в стан об'єкту  $Y$ , де  $X$  – вхідні данні, що характеризують рівень навченості, мотивацію, когнітивні здібності учня (наприклад, вступ абітурієнта до ВНЗ),  $Y$  – вихідні данні, що характеризують досягнутий рівень навченості (наприклад, посадових компетенцій випускника ВНЗ). З середовища можна виділити суб'єкт управління, який є джерелом мети для об'єкта. В широкому сенсі суб'єктом є суспільство, що формує за допомогою відповідних інституцій соціальні вимоги до якості оволодіння випускниками певними посадовими компетенціями, які регламентуються освітніми стандартами. Так, уявимо, що суб'єкт формулює свою мету  $Z$ , реалізація якої в об'єкті призводить до задоволення потреб суб'єкта:

$$Y \in Z \quad (3.5)$$

Педагогічна система є середовищем, в якому за певною технологією реалізується процес навчання. В структурі ПС можна визначити елементи, що утворюють дві взаємозв'язані групи: групу елементів, що формулюють дидактичну задачу, і групу елементів, що утворюють педагогічну технологію, яка гарантовано вирішує цю задачу.

Структура ПС в співвідношенні із ДС показано на рис.3.6. Дидактична система складається з методів, форм і засобів навчання.

Функція ДС полягає у визначенні наступних характеристик управління:

1. вид управління, під яким розуміють реакцію на пізнавальну діяльність;
2. вид інформаційного процесу;
3. засіб управління.

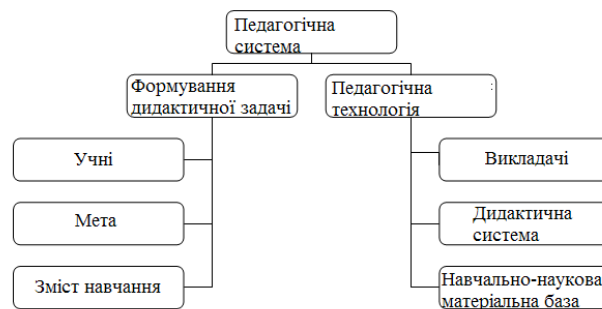


Рисунок 3.6 - Структура педагогічної системи

На основі дидактичного аналізу постановки задачі визначимо основні елементи, що утворюють ДС, яка проектується. До них відносяться множини методів навчання  $m_1, m_2, \dots, m_k$ , форм навчання  $f_1, f_2, \dots, f_l$ , засобів навчання  $s_1, s_2, \dots, s_m$ , множина монодидактичних систем  $\{ds_1, ds_2, \dots, ds_n\} \in DS$  і множина навчальних елементів (НЕ)  $le_1, le_2, \dots, le_n$ , вивчення яких передувє вивченню поточного навчального елементу  $le_{n+1}$ , для навчання якому проектується ДС.

Взаємозв'язки між елементами (рис.3.7) утворюють множину вагових коефіцієнтів, які відповідають ступеню доцільності вибору методів, форм та

засобів навчання – для проміжного шару, множину бінарних значень, на основі яких встановлюється тип монопредметної ДС.

Таким чином, формальна модель утворення ДС має вигляд структурно-параметричного опису у вигляді спрямованого зваженого графу, ваги якого визначаються на основі знань експертів – викладачів-«предметників» для вихідного шару. Структура, що представлена, з оглядом на відсутність аналітичних залежностей відображення взаємозв'язків між вертикальними шарами, доцільно реалізувати у вигляді багатошарової нейронної мережі. Вхідний шар утворює сумарну характеристику множини навчальних елементів, що передують вивченню НЕ, вивчення якого розглядається:

$$\sum_{i=1}^n l e_i = \sum_{i=1}^n a_i + \sum_{i=1}^n b_i + \sum_{i=1}^n c_i + \sum_{i=1}^n K n_i, \quad (3.6)$$

де  $n$  - кількість НЕ, що входять до ДС, що проектується;

$a$  - ступень абстракції НЕ ( $a \in \{2, \dots, 4\}$ );

$b$  - рівень засвоєння НЕ ( $b \in \{2, \dots, 4\}$ );

$c$  - ступінь усвідомленості засвоєння (алгоритмічний, внутрішньопредметний, міжпредметний, системний);

$K n$  - коефіцієнт автоматизації або навички ( $0 \leq K n \leq 1$ ).




Рисунок 3.7 - Структурна схема визначення типу ДС

На структурній схемі ДС (рис.3.7) вхідний шар умовно позначений узагальненою характеристикою  $l e_i$ . Але правила, що складені на основі

міркувань експертів щодо доцільних форм, методів та засобів навчання для переведення моделі особи, що навчається, зі стану навченості  $le_n$  у стан навченості  $le_{n+1}$ , містять чисельні значення кожного з параметрів НЕ, мають наступний вигляд:

$$\text{ЯКЩО } e_i = \alpha_1 \text{ I } e_{n+1} = \alpha_2, \text{ ТО } m = \beta_1 \text{ I } f = \chi_1 \text{ I } s = \delta_1 (F_j) , \quad (3.7)$$

де  $e_i, e_{n+1}$  - найменування лінгвістичної змінної, що відповідає характеристикам НЕ (3.2) для початкового та поточного НЕ відповідно;

$\alpha_1, \alpha_2$  - значення лінгвістичних змінних відповідних характеристик початкового та поточного НЕ відповідно;

$m, f, s$  - найменування лінгвістичних змінних, що відповідають елементам дидактичної системи (методам, формам та засобам навчання);

$\beta_i, \chi_i, \delta_i$  - значення лінгвістичних змінних, що висловлюють назви методів, форм та засобів навчання відповідно;

$F_j (j \in \{2, \dots, n\})$  - коефіцієнти впевненості або вагові коефіцієнти відповідних правил, що виражають ступень впевненості експерта щодо взаємозв'язку.

Вхідні елементи проміжного шару є об'єднанням множин елементів ДС:  $\{m_1, m_2, \dots, m_k\} \cup \{f_1, f_2, \dots, f_l\} \cup \{s_1, s_2, \dots, s_m\}$ , що мають бінарний вираз синаптичних важелів. Навчання нейронної мережі по визначенню виду ДС здійснюється на основі набору правил продукцій, які відображають розсуд експерта – спеціаліста в галузі дидактики з приводу відповідності трійки  $\langle m_k, f_l, s_m \rangle$  однієї з восьми (або дванадцяти – в разі дистанційного навчання) відомих дидактичних систем -  $DS$ . Правила мають наступний вигляд:

$$\begin{aligned} \text{ЯКЩО } \langle m = \beta_1 \text{ I } f = \chi_1 \text{ I } s = \delta_1 \rangle \text{ АБО } \langle m = \beta_1 \text{ I } f = \chi_2 \text{ I } s = \delta_1 \rangle \\ \text{АБО } \dots, \text{ ТО } DS = ds_j \langle \epsilon_j \rangle \end{aligned} \quad (3.8)$$

де  $DS$  - ім'я лінгвістичної змінної для присвоєння одного з її значень, що відповідають монодидактичній системі.

У зв'язку з тим, що думки експертів, на основі яких формулюються правила, не можуть бути висловлені точними чисельними значеннями, то вони створюють систему нечітких правил. Для здійснення класифікації дидактичної ситуації, що склалася, з точки зору визначення доцільної ДС, ґрунтовним є вибір нейро-нечіткої мережі [9]. До безперечних переваг такого підходу відноситься здатність до навчання, що притаманна нейромережам, водночас із можливістю модифікації нечітких правил прийняття рішень. Крім того, синтез вказаних інтелектуальних засобів дозволяє виконати первісне проектування нейронної мережі на основі експертних оцінок з подальшим оцінюванням коректності функціонування такої системи. Для співставлення ДС, що проектуються, використовується система показників ефективності: рівень засвоєння, швидкість виконання дії, трудомісткість, вартість, стабільність (розкид результатів), час навчання. У випадку незадовільних значень наданих показників ефективності, правила можуть бути уточненими.

Нейро-нечітка модель формування ДС для навчання поточного НЕ, що запропонована, складає основу для генерації послідовності монодидактичних систем. Така послідовність є полідидактичною ДС, а правила щодо відповідності конкретній дидактичній ситуації можуть бути добавленими в нечітку базу знань. Таким чином, розроблена модель та її нейро-нечітка реалізація дозволяють автоматизувати доволі складний та трудомісткий процес вибору ДС.

Для реалізації інформаційної підсистеми, що виконує генерацію послідовності монодидактичних систем, використано пакет Fuzzy Logic Toolbox, що входить до складу системи Matlab [10]. За допомогою редактора нечітких нейронних мереж ANFIS Editor здійснюється створення структури нечіткої нейронної мережі, перегляд структури, налагодження її параметрів, перевірка якості функціонування мережі.

На рис. 3.8 показана структура нейро-нечіткої мережі, за допомогою якої за вхідними змінними  $a$ ,  $b$ ,  $c$ ,  $K_n$ , що є параметрами НЕ дидактичної задачі,

на основі бази нечітких правил визначається вид дидактичної системи. В якості вихідних даних мережі розглянуто вісім базових монодидактичних систем.

Для виконання логічної кон'юнкції застосовується метод мінімального значення, для виконання логічної диз'юнкції – метод максимального значення. В якості метода виведення висновку (активізації логічного виведення в кожному з нечітких правил) обрано метод мінімального значення. В якості метод агрегування обрано метод максимального значення, а методом дефазифікації – centroid.

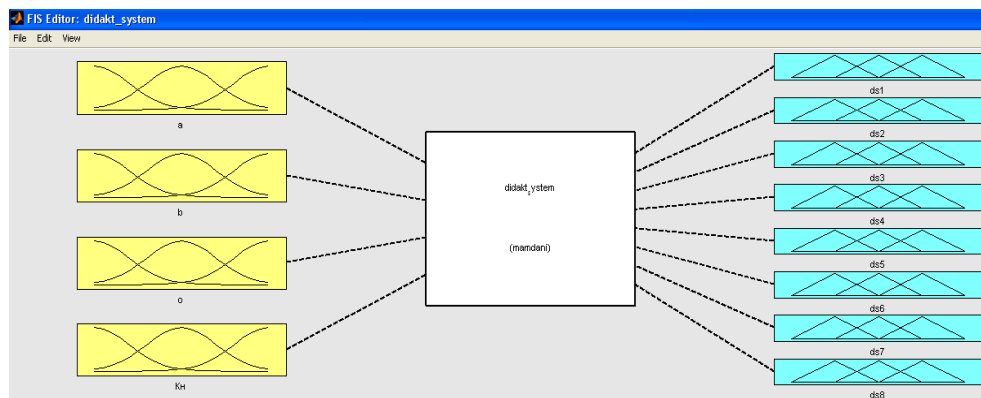


Рисунок 3.8 - Структура нейро-нечіткої мережі з визначення типу ДС

За допомогою редактора функцій належності введено значення вхідних лінгвістичних змінних. Сформовано нечіткі правила, що складені на основі опитування експертів. На рис. 3.9 наведено один з результатів роботи програми перегляду поверхні нечіткого висновку. Програма дозволяє на основі загального аналізу оцінити вплив зміни значень вхідних нечітких змінних на значення вихідних нечітких змінних.

Запропонована модель а її реалізація до визначення вида ДС на основі нечіткого виведення дозволяє автоматизувати один з найбільш складних етапів створення педагогічної системи. Послідовність рекомендованих ДС утворює полідидактичну систему. Оцінка її ефективності є основою для поповнення бази нечітких правил відсутніми відомостями щодо взаємозв'язку між вхідними та вихідними параметрами.

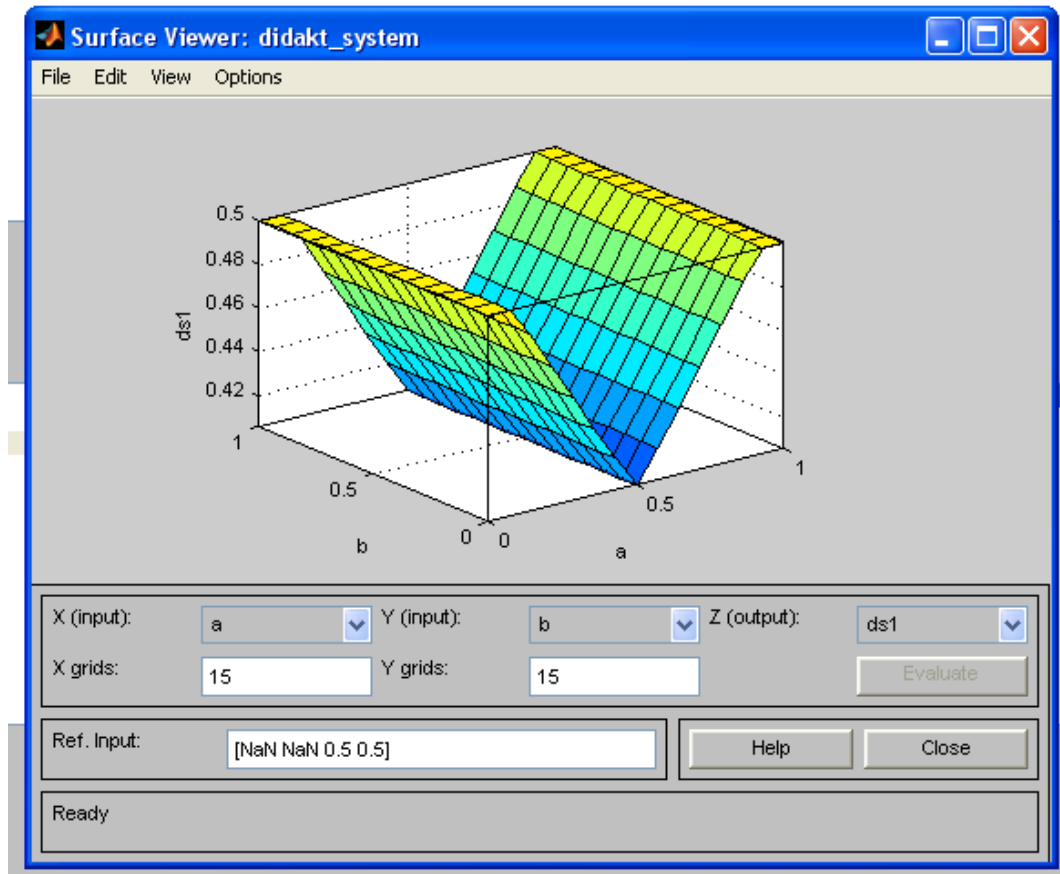


Рисунок 3.9 - Поверхня нечіткого висновку для розробки нечіткої моделі Комп'ютерні експерименти, що проводились в Південноукраїнському національному педагогічному університеті ім. К.Д. Ушинського (м. Одеса), підтвердили можливість генерації послідовностей ДС у відповідності до дидактичної задачі для кожного НЕ. Експерименти проводились для проектування ДС, що реалізовувалась в системі управління навчанням дистанційного курсу «Методика викладання інформатики». Отримані результати дозволяють не тільки ефективно управляти самостійною роботою студентів, але й здійснювати інтелектуальну підтримку викладача в «безкомп'ютерному» навчанні [11].

Практична значущість реалізації даного підходу визначається важливістю адекватного формування ДС для підвищення якості навчання за рахунок об'єктивного врахування сукупності нечітко визначених факторів, які впливають на результативність процесу навчання.

### **3.3. Нейромережева реалізація системи міжпредметних зв'язків**

Згідно моделі системи міжпредметних зв'язків (рис.2.19), яка є основою для визначення коефіцієнту інтеграції відповідної структурної одиниці навчання, сформуємо нейронну мережу, що є моделлю системи міжпредметних зв'язків.

Теорія формування міжпредметних структур навчальних знань базується на психолого-педагогічних дослідженнях закономірностей асоціативного процесу, що має місце при використанні міжпредметних зв'язків [12]. Тому пропонується формалізувати міждисциплінарний об'єкт навчання на основі впровадження моделі асоціативного мислення.

Таким чином, задача полягає в створенні моделі системи міжпредметних зв'язків, як основи для реалізації інтегративного підходу в управлінні навчанням з використанням асоціативного мислення.

Аналіз існуючих підходів до моделювання навчальних курсів відображає загальну тенденцію до створення ієрархічних моделей, елементами якої є відповідні навчальні елементи. Вершиною ієрархії є курс, або НД, найнижчим елементом – окреме поняття теми. Принцип уніфікації навчального елемента визначає найбільш вагомим саме останній рівень ієрархії – навчальний елемент.

Модель опису процесу асоціативного мислення розглядається нами як ланцюг, який зв'язує логічну модель і модель нейронної мережі, що відповідає тенденції у розвитку систем штучного інтелекту до створення гібридних систем [13].

Асоціативний механізм є подібним до встановлення міжпредметних зв'язків. Головна відмінність результату полягає в високому рівні суб'єктивізму та фрагментарності встановлення зв'язків «вручну» з боку викладача. Застосування логічного підходу зменшує частку суб'єктивізму за рахунок формування правил на основі набуття знань від експертів, однак не вирішує питання відтворення цілісності структури міжпредметних зв'язків.



Дослідження роботи мозку [14-16] визначили, що найбільш важлива можливість і його структурна особливість полягає в зберіганні великих об'ємів інформації не окремими нейронами, а нейронними групами (ансамблями). Найбільш сильним обмеженням є неприпустимість одночасної активності великої кількості нейронних ансамблів. Наслідком цього обмеження є проблеми сприйняття-видимості явищ та процесів, розриви в цілісному сприйнятті, перемикання та активізація уваги та інші традиційні проблеми навчання.

В ансамблях нейронів частина (підгрупа) нейронів сильно пов'язана між собою (рис.3.10). Ця підгрупа – ядро, відповідає за стійку частину образу, поняття, яка відображає в мозку людини конкретний об'єкт реального світу.




Рисунок 3.10 - Ансамблі асоціативного механізму

Але існування тільки стійких частин призвело б до статичності віртуального образу світу, що не припускає розвитку. Мінливість та розвиток забезпечується за рахунок частини слабо зв'язаних нейронів – бахроми. Тоді робота механізму асоціацій полягає в об'єднанні одного активного ансамблю з іншим, в наслідок чого здійснюється замикання областей (рис.3.11).

Ядра ансамблів нейронів складного образу формуються в наслідок багатократного надання складових образів, що аналогічно за своєю суттю використанню НЕ при вивченні різних навальних дисциплін.




Рисунок 3.11 - Об'єднання областей А і В

Тому особливий інтерес викликає процес пошуку зв'язаних асоціативно з даним образом інших образів, які прив'язані к іншим предметним областям. Такий процес в природних інтелектуальних системах реалізується в корі головного мозку і становить основу всієї розумової діяльності живої істоти [15].

Ефективність різних форм інтегрованого навчання проявляється в формуванні на рівні уявної моделі (в свідомості учня) певних наборів асоціацій, які допомагають йому в подальшій професійній діяльності відновити за неповними даними весь образ за асоціативно обумовленими зв'язками. Тому модель системи міжпредметних зв'язків доцільно сформувавши на основі моделі асоціативного мислення [17]. Таким чином, формування еталонних образів у вигляді наборів асоціацій здійснюється на основі вилучення знань щодо об'єктивно існуючих зв'язків між відповідними навчальними дисциплінами. Ця система асоціацій, в свою чергу, є відображенням інтегративних зв'язків в науці. Подальше використання моделі пов'язано із встановленням відповідних наборів коефіцієнтів інтеграції, що забезпечують відтворення потрібного образу. Крім того, асоціації, які не активуються за визначений час, тобто залишаються без підкріплення, можуть бути знищені.

Припустимо, що множина ознак  $X = \{x_i | i=1, N_a\}$  задає опис стану об'єкта в деякий момент часу  $t$ ,  $N_a$  - кількість ознак. В загальному випадку ознаки з множини  $X$  є числами, що визначені на метричних шкалах. Однак, в окремих

випадках, ознаки можуть бути бінарними. Множина комбінацій значень ознак на множині  $X$  становить  $B_o = \prod_{j=1}^{N_o} B_j$ , де  $N_o$  - кількість образів. Множина реальних (тобто не з повним набором ознак)  $B = \prod_{j=1}^{N_o} B_j$ ,  $k = 1, N_a$ . Нехай образ, що ініціює асоціативний пошук, позначимо  $P$ , образ-результат асоціативного пошуку -  $R$ .

Пара образів  $\langle B, R \rangle$  є асоціацією  $A$  або  $A \langle B, R \rangle$ , предикат  $\Xi \langle B_a, R_a, T_a \rangle$  описує встановлення  $R_a | R_a \subseteq R$  за  $B_a | B_a \subseteq B$ , де  $B_a$  - початковий образ асоціативного пошуку,  $R_a$  - кінцевий образ асоціативного пошуку,  $T_a$  - час асоціативного пошуку. Будемо вважати, що асоціативний пошук є елементарним, тобто використовує тільки одну асоціацію, що міститься в базі знань, тому для системи с дискретним часом елементарний пошук відповідає одному кроку часу пошуку  $\langle T_a \rangle = 1$ .

Для реалізації моделі асоціативного пошуку застосуємо функціонування нейронної мережі Хопфілду [18]. Нейронна мережа Хопфілду є мережею автоасоціативної пам'яті, яка реалізує відображення та відновлення за часткою образу найближчого до нього еталонного. За архітектурою – це рекурентна одношарова мережа, в якій вихід кожного нейрона з'єднаний з входами всіх останніх нейронів (рис.3.12). Початковий стан мережі визначається вхідним вектором, кінцевим станом – стан рівноваги мережі, в наслідок чого встановлюється вихідний відновлений зразок. Стан рівноваги встановлюється за умови досяжності в мережі мінімуму функції енергії.

На стадії ініціювання мережі вагові коефіцієнти встановлюються наступним чином:

$$w_{ij} = \begin{cases} \sum_{k=0}^{m-1} x_i^k x_j^k, & i \neq j \\ 0, & i = j \end{cases}, \quad (3.9)$$

де  $i, j$  - індекси, відповідно, передсинаптичного та постсинаптичного нейронів,  $x_i^k, x_j^k$  -  $i$ -ий та  $j$ -ий елементи вектора  $k$ -го зразка.




Рисунок 3.12 - Структурна схема мережі Хопфілда

Алгоритм функціонування мережі Хопфілду складається з наступних кроків:

Крок 1. На входи мережі подається невідомий сигнал.

Крок 2. Обчислюється новий стан нейронів:

$$s_j^{(p+1)} = \sum_{i=0}^{n-1} w_{ij} y_i^{(p)}, j = 0, n-1, \quad (3.10)$$

та нові значення аксонів:

$$y_j^{(p+1)} = f | s_j^{(p+1)} \quad (3.11)$$

де  $p$  - номер ітерації;

$f$  - лінійна функція активації з насиченням.

Крок 3. Перевірка наявності змін вихідних значень аксонів за останню ітерацію. Якщо «так» - перехід до кроку 2, інакше – кінець. При цьому вихідний вектор є зразком, що найкращим чином поєднується з вхідними даними.

Таким чином, за скінченну кількість ітерацій (тактів часу) мережа з довільного початкового стану приходиться до стану стійкої рівноваги, що називається атрактором.

Проектування мережі Хопфілду – це процес створення рекурентної мережі із множиною точок рівноваги, таких, що при наданні початкових умов мережа перейде в стан покою в одній з них. Властивість рекурсії проявляється в тому, що вихід мережі подається на вхід. До особливостей

метода синтезу мережі Хопфілду є зменшення паразитних точок рівноваги в процесі налагодження під час комп'ютерних експериментів.

Для комп'ютерної реалізації системи міжпредметних зв'язків, як моделі відбиття еталону асоціативного мислення обрано засоби інструменту Neural Networks Toolbox (NNT) пакету Matlab [18].

Архітектуру модифікованої мережі Хопфілда наведено на рис.3.13 [2].

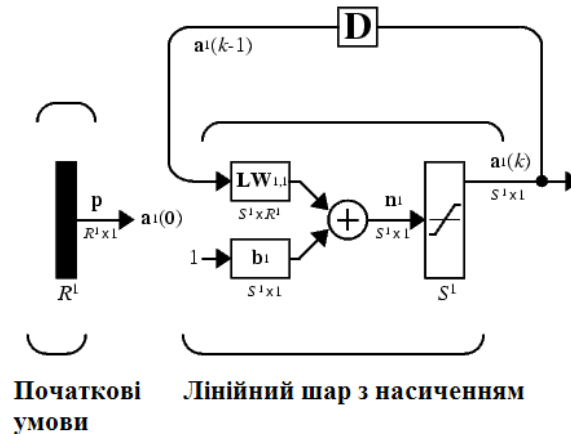


Рисунок 3.13 - Архітектура мережі Хопфілду

Вхід  $p$  встановлює значення початкових умов. В мережі використовується лінійна функція активації з насиченням *satlins*, яка описується наступним чином:

$$a = \text{satlins}(n) = \begin{cases} -1, & n < -1; \\ n, & -1 \leq n \leq 1; \\ 1, & n > 1. \end{cases} \quad (3.12)$$

В NNT реалізовано алгоритм синтезу на основі методу проектування модифікованих мереж Хопфілда у вигляді підфункції *solvehop2(t)* М-функції *newhop*.

Якщо задано множину цільових точок рівноваги, що надано матрицею  $T$ , то функція *newhop* повертає матрицю ваг та вектор зміщень для рекурентного шару мережі Хопфілда. При цьому гарантується, що точки стійкої рівноваги будуть відповідати цільовим векторам, але можуть з'явитись паразитні точки. В процесі синтезу мережі кількість таких небажаних точок зводиться до мінімуму.

Нехай задано  $Q$  цільових векторів, що утворюють матрицю  $T$  розміру  $S \times Q$ :

$$T = \begin{bmatrix} t_1 & t_2 & \dots & t_{Q-1} & t_Q \end{bmatrix}. \quad (3.13)$$

Утворимо нову матрицю  $Y$  розмірністю  $S \times Q - 1$  наступного вигляду:

$$Y = \begin{bmatrix} -t_Q & t_2 - t_Q & t_{Q-1} - t_Q \end{bmatrix}. \quad (3.14)$$

Розклад матриці  $Y$  за сингулярними числами:

$$Y = \sum_{i=1}^S \sigma_i u_i v_i^T. \quad (3.15)$$

Отримуємо матриці:

$$TP = \sum_{i=1}^K u_i u_i^T, \quad TP = \sum_{i=K+1}^S u_i u_i^T, \quad (3.16)$$

де  $K$  - ранг матриці  $Y$ .

Тоді динамічна система має наступне представлення:

$$x' = T_\tau x + \mathbf{E} - T_\tau \vec{t}_Q, \quad (3.17)$$

де  $T_\tau$  - матриця вигляду  $TP - \tau TM$ ;  $\tau$  - динамічний параметр (в алгоритмі прийнято рівним 10);  $E$  - одинична матриця.

Для системи (3.17) обчислимо дискретну модель:

$$x_k = \Phi x_{k-1} + Ft_Q, \quad (3.18)$$

де  $\Phi$  - перехідна матриця вигляду  $e^{T_\tau h}$ ;  $F$  - матриця передачі входу вигляду

$$F = \mathbf{E} TP + c_2 TM \mathbf{E} - T_\tau, \quad c_1 = e^h - 1, \quad c_2 = \mathbf{E} - e^{-\tau h} \mathbf{E}; \quad h - \text{такт дискретності}$$

(в алгоритмі прийнятий рівним 0,15 с).

Відповідна матриця ваг рекурентного шару і вектор зміщення обчислюються наступним чином:

$$\begin{cases} W = \Phi; \\ b = Ft_Q. \end{cases} \quad (3.19)$$

Мережа, що спроектована, може бути перевірена векторами входу на приналежність вершинам гіперкубу, визначити області тяжіння цих точок, знайти паразитні точки, якщо вони є.

Розглянемо створення модифікованої мережі Хопфілда з 9 нейронами, визначимо в якості профілів інтегрування набори даних, що мають стійку рівновагу в наступних точках тривимірного простору (3 стабільні рівноваги – за стовпчиками):

$$T = [1 \ -1 \ -1; 111; -111]'$$

Проектування мережі здійснюється з використанням М-функції *newhop* :

```
net=newhop(T);
```

Перевіримо, чи належать вершини мережі Хопфілда:

```
Ai=T;
```

```
[Y,Pf,Af]=sim(net,4,[],Ai)
```

Отримуємо:

```
>> Y
```

```
Y =
```

```

     1     1    -1
    -1     1     1
    -1     1     1
```

Дійсно, стійкі положення рівноваги мережі знаходяться в зазначених точках.

Розрахуємо ваги та зміщення модифікованої мережі Хопфілда:

```
W=net.LW{1,1}
```

```
b=net.b{1,1}
```

```
>> W
```

```
W =
```

```

    1.1618    0.0000   -0.0000
    0.0000    0.6925    0.4694
   -0.0000    0.4694    0.6925
```

```
>> b

b =

    1.0e-016 *

    -0.1797
     0.0000
     0.0000
```

Перевіримо поведінку мережі при випадкових початкових умовах:

```
a={rands(3,1)};
[y,Pf,Af]=sim(net,{1 10},{},a);
record=[cell2mat(a) cell2mat(y)];
start=cell2mat(a);
hold on
plot3(start(1,1), start(2,1),start(3,1), 'bx', record(1,:), record(2,:), record(3,:))
color='rgbmy';
for i=1:25
    a={rands(3,1)};
    [y,Pf,Af]=sim(net,{1 10},{},a);
    record=[cell2mat(a) cell2mat(y)];
    start=cell2mat(a);
    plot3(start(1,1), start(2,1),start(3,1), 'kx', record(1,:), record(2,:),
record(3,:),color((rem(i,5)+1))
end
```

Результат перевірки роботи мережі Хопфілда при випадкових початкових умовах представлений на рис. 3.14:

Таким чином, отримуємо в якості інструментарію для перетворення інформації щодо доцільних взаємозв'язків між НД, яка представлена бінарними значеннями цільових точок, в інформацію щодо коефіцієнтів інтеграції, які забезпечують потрібний рівень взаємозв'язків. Запропонований метод моделювання системи міжпредметних зв'язків має



теоретичне підґрунтя, що засновано на аналогії асоціативного мислення, дозволяє навіть у відсутності «задачника» налагодити мережу, визначити потрібні вагові коефіцієнти, що відповідають ступеню взаємозв'язку. Це є важливим елементом у синтезованій системі управління індивідуалізованим навчанням.

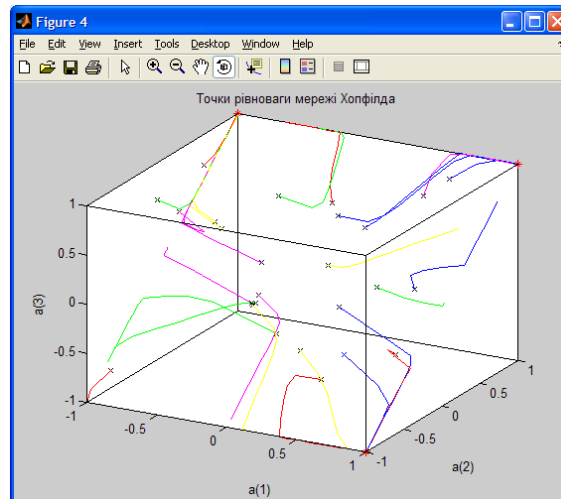


Рисунок 3.14 - Результат перевірки роботи мережі

Однак, для формування індивідуалізованих стратегій навчання, необхідно мати не тільки модель системи міжпредметних зв'язків, але й відповідний інструментарій забезпечення й керування взаємодією з системою компетенцій. Тому розглянемо метод формування нечітких правил для встановлення причинно-наслідкових правил між цими системами.

### **3.4 Нечітка кластеризація взаємозв'язків між системою міжпредметних зв'язків та системою компетенцій**

Одним з важливих елементів СУ КМП (рис.2.10), СУ СКМП (рис.2.11) є налагодження взаємодії між системою міжпредметних зв'язків та системою компетенцій. З оглядом на специфіку цього відношення, яка полягає у відсутності точних вимірів відповідних характеристик, суб'єктивності оцінки відношення, апріорно визначений його нелінійний характер, а також спираючись на запропоновані моделі, розглянемо реалізацію нечіткої

кластеризації, як основу для синтезу нечітких правил щодо встановлення причинно-наслідкових зв'язків між двома системами.

Дослідження та розробка нечіткої системи будемо здійснювати за допомогою інструментарію Fuzzy Logic Toolbox програми Matlab.

Для знаходження центрів кластерів в Matlab існує функція `subclust`, яка призначена для здійснення так званої субтрактивної кластеризації та має наступний синтаксичний опис [19]:

$$[\text{centers, sigmas}] = \text{subclust}(X, \text{radii}, \text{xBounds}, \dots, \text{options}).$$

Дана функція обчислює центри кластерів даних за вдосконаленим гірським алгоритмом субтрактивної кластеризації. Кількість кластерів визначається під час роботи алгоритму по здійсненню розподілу даних. Функція `subclust` може мати до чотирьох вхідних аргументів, перші два з них – обов'язкові:

1. `X` – данні для кластерного аналізу. Кожний рядок матриці `X` задає один об'єкт кластеризації;

2. `radii` – вектор, що визначає розміри кластерів по кожній координаті. Координати вектора `radii` повинні знаходитись в діапазоні  $[0, 1]$  у зв'язку із тим, що при кластеризації данні `X` масштабуються на одиничний гіперкуб. Рекомендовано назначати значення `radii` з діапазону  $[0,2 \ 0,5]$ . Крім того, у випадку рівнозначних координат, `radii` задається скаляром.

3. `xBounds` – матриця діапазонів зміни вхідних даних, яка необхідна для масштабування матриці `X` на одиничний гіперкуб. Кожний рядок задає зміну даних з однієї координати. Якщо цей аргумент не задано, то відповідні діапазони обчислюються за фактичними значеннями матриці `X`.

4. `options` – вектор параметрів кластерного аналізу:

`options(1)` – коефіцієнт подавлення. Чим більше його значення, тим більше сусідніх елементів буде належати кластерові. За умовчанням дорівнює 1,25;

`options(2)` – коефіцієнт прийняття. Чим більше його значення, тим більше кластерів буде знайдено. За умовчанням дорівнює 0,5;

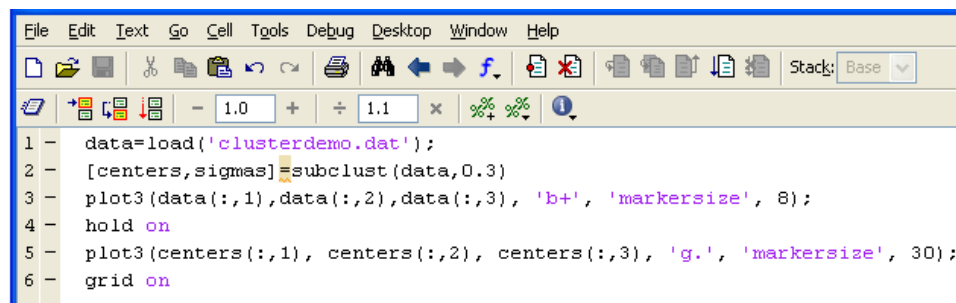
options(3) – коефіцієнт відторгнення. Чим менше його значення, тим більше віддалених один від одного кластерів може бути знайдено. Значення коефіцієнта відторгнення повинно бути менше значення коефіцієнта прийняття. За умовчанням дорівнює 0,15;

options(4) – управління виводом на екран поточних результатів кластерного аналізу. Якщо встановлено нульове значення, то вивід поточних результатів подавлено.

Функція subclust може мати до двох вихідних аргументів:

1. centers – матриця центрів кластерів, що знайдені. Кожний рядок матриці представляє координати центру одного кластеру;
2. sigmas – вектор радіусів кластерів.

Виклик вбудованої в Matlab функції кластеризації та візуалізація отриманих результатів записано в скрипт Cluster.m (рис.3.15).



```

File Edit Text Go Cell Tools Debug Desktop Window Help
[Icons] Stack: Base
- 1.0 + 1.1 x
1 - data=load('clusterdemo.dat');
2 - [centers,sigmas]=subclust(data,0.3);
3 - plot3(data(:,1),data(:,2),data(:,3),'b+', 'markersize', 8);
4 - hold on;
5 - plot3(centers(:,1), centers(:,2), centers(:,3), 'g.', 'markersize', 30);
6 - grid on

```

Рисунок 3.15 - Зміст скрипта Cluster.m.

В цьому скрипті дані для кластеризації надано у вигляді файлу clusterdemo.dat. У зв'язку із тим, що зазвичай для користувачів більш зручним є накопичення даних в електронних таблицях (наприклад, за допомогою програми MS Excel), то вважаємо за доцільне використання інтерфейсу для доступу до ресурсів середовища Matlab з середовища електронних таблиць. Такий інтерфейс зв'язку (Excel Link) розроблений фірмою MathWorks, входить до складу програмних продуктів середовища Matlab [19]. Він забезпечує можливість обміну даними між робочими областями розглянутих систем та дозволяє реалізовувати команди Matlab, не

виходячи з середовища MS Excel. На рис. 3.16 показано схему взаємодії MS Excel і системи Matlab.

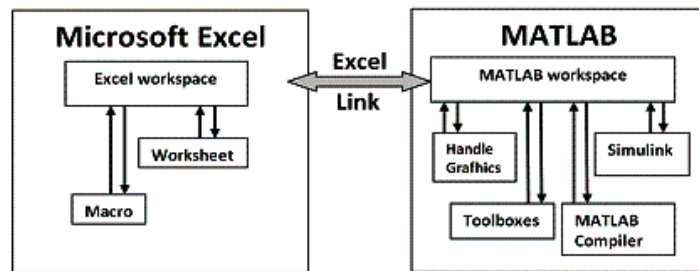


Рисунок 3.16 - Схема взаємодії MS Excel і системи Matlab

Запуск інтерфейсу здійснюється за наступним алгоритмом:

1. Виклик MS Excel.
2. В меню сервіса Tools вибрати підменю настройки Add-Ins та опцію обзору Browse.
3. В MATLAB\Toolbox\Exlink знайти шлях до файлу exclink.xla та обрати його.

Після цього стає доступним нове підменю, серед опцій якого є функції для здійснення взаємозв'язку між даними. Так, для того, щоб передати таблицю даних для кластеризації оберемо функцію putmatrix (вставити в матрицю), вкажемо її ім'я в Matlab (рис.3. 17).

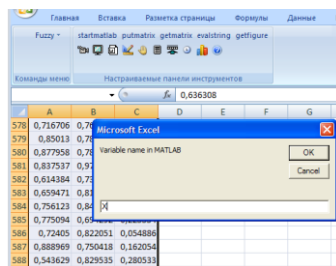


Рисунок 3.17 - Імпорт даних з таблиці MS Excel

Тоді в скрипті може використовуватись замість файлу матриця X. Для наведеного набору даних (табл. А.1) наслідком кластеризації є отримання в командному вікні Matlab координат трьох кластерів та їх радіуси:

centers =

```
0.2220  0.5937  0.8113
0.5914  0.1721  0.4872
```

0.7797 0.8191 0.1801  
 sigmas =  
 0.1142 0.1193 0.1350.

Графічне відображення результатів кластеризації наведено на рис.3.18, де центри знайдених кластерів вказано кружечками.

Далі, за результатами кластеризації можна синтезувати нечіткі правила, які зв'яжуть вхід із виходом, тобто забезпечать ідентифікацію взаємозв'язку між коефіцієнтами інтеграції між парами НД та ступенем досяжності відповідних компетенцій.

Для генерування з даних, що отримані в наслідок субтрактивної кластеризації, системи нечіткого висновку – Fuzzy Inference System (FIS) призначена функція `genfis2`. Функція генерує із даних нечітку систему типу Сугено з використанням субтрактивної кластеризації. Слід зазначити, що у зв'язку з тим, що в даній постановці маємо данні з однією вихідною змінною, то результат виконання функції може розглядатися к вхідна нечітка система для ANFIS-навчання [20]. Екстракція нечітких правил здійснюється в два етапи. По-перше функція `subclust` знаходить посилки нечітких правил. По-друге, за методом найменших квадратів обчислюються висновки правил. В наслідок чого отримуємо систему нечіткого висновку з базою правил, що охоплює всю предметну галузь.





Рисунок 3.18 - Результати кластеризації

Функція `genfis2` може мати до п'яти наступних вхідних параметрів, перші три з яких є обов'язковими:

`fis=genfis2(Xin, Xout, radii, xBounds, options),`

1.  $X_{in}$  - матриця, кожний рядок якої містить значення вхідних змінних;
2.  $X_{out}$  – матриця, кожний рядок якої містить значення вихідних змінних;
3.  $radii$  – вектор, що визначає «області впливу» центрів кластерів по кожній вхідній змінній. Якщо значення задано скаляром, то всі координати вважаються рівноважними;
4.  $xBounds$  – матриця діапазонів змін даних для їх масштабування. Якщо аргумент не заданий, то діапазони обчислюються за фактичними значеннями матриць  $X_{in}$ ,  $X_{out}$ ;
5.  $options$  – вектор параметрів кластерного аналізу, інформацію о яких наведено в описі функції `subclust`.

На основі аналізу освітньо-професійної програми підготовки бакалаврів за напрямком 0925 «Автоматизація та комп'ютерно-інтегровані технології» [21], наприклад, можна визначити, що система компетенцій складається з приблизно 75 компетенцій, що містяться в таблиці змістовних модулів під відповідними шифрами. Згідно рекомендованому переліку навчальних дисциплін, формування СКМП здійснюється на основі вивчення понад 40 навчальних дисциплін. За таких умов, в загальному випадку, на основі (3.39) матриця кластеризації має розмірність  $100 \times 780$ , т. я.  $ns = (40^2 - 40) \cdot 2 = 780$ .

Однак, обробка всієї матриці таких значних обсягів не є доцільною, бо формування СКМП при стаціонарному навчанні здійснюється на протязі 8 навчальних семестрів. Припускаючи рівномірний розподіл формування компетенцій та відповідне вивчення забезпечуючи їх дисциплін, отримуємо розмірність матриці  $12 \times 98$ .

Таблиці даних для кластеризації наведено в табл. Б.1. Результати кластеризації для матриці вигляду (2.71), рядки якої відповідають формуванню дванадцяти компетенцій (шифри ПФ.Е.01, ПР.О.01, ПФ.Е.02, ПР.Р.02, ПФ.Д.04, ПР.Р.04, ПФ.Е.05, ЗР.Р.05, ПФ.Д.01, ПР.О.01, ПФ.С.01, ПП.О.01) [21]. Наприклад, ПФ.Е.01 відповідає компетенції – «**вміння** при експлуатації системи автоматизації ... проведення метрологічного контролю

за розробленням, виробництвом, станом, застосуванням засобів вимірювання, за впровадженням та додержанням метрологічних норм та правил; ...». Столпчики матриці утворюють вектор коефіцієнтів інтеграції між десятьма навчальними дисциплінами з циклу професійної та практичної підготовки, серед яких – метрологія, технологічні вимірювання та прилади, технічні засоби автоматизації, електроніка та електромеханіка та ін. (табл. Б.1).

В результаті кластеризації отримано координати центрів класів та вектор їх радіусів:

```
centers =
    0.3351    0.5344    0.4833
    0.7103    0.2428    0.3422
    0.6786    0.7919    0.5798
    0.4851    0.2340    0.8299
    0.1865    0.8790    0.7869
    0.8684    0.6804    0.1959
    0.1793    0.1428    0.3024
    0.8551    0.5927    0.9440
    0.2128    0.7710    0.1419
    0.9168    0.1544    0.8025
    0.1238    0.1136    0.7248
    0.5398    0.4233    0.0044

sigmas =
    0.1765    0.1766    0.1762
```

Графічна візуалізація розподілу центрів класів наведено на рис. 3.19. За результатами кластеризації можна визначити, міжпредметні зв'язки між якими навчальними дисциплінами мають споріднені кількісні ознаки для формування розглянутих компетенцій.




Рисунок 3.19 - Результати кластерного аналізу матриці формування компетенцій бакалаврів

Подальшу генерацію правил нечіткого виводу будемо здійснювати на основі використання функції `genfis2` з наступними параметрами:

$$\text{fis}=\text{genfis}(X,Y,0.5),$$

де  $X$  – матриця коефіцієнтів інтеграції між парами десяти НД

$Y$  - вектор-стовбець, що відповідає ступеню досяжності відповідної компетенції на основі експертних оцінок.

На основі попередньої кластеризації кількість правил нечіткої бази знань становить дванадцять. Відповідна структура нейрон-нечіткої мережі, що є результатом генерації редактору ANFIS, наведено на рис. 3.20.

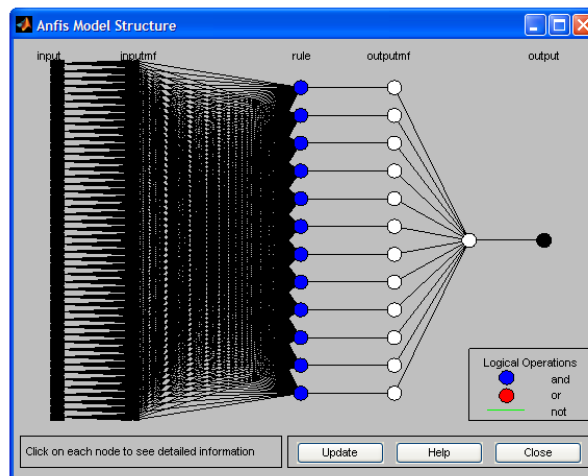


Рисунок 3.20 - Структура нейронної нечіткої мережі ANFIS

Таким чином, за рахунок попередньої кластеризації вдалось значно ефективніше застосувати генерацію нечітких правил, кількість яких співпадає з кількістю кластерів.

Отримана система дозволяє ідентифікувати характер взаємозв'язку між матрицею коефіцієнтів інтеграції та ступенем досягнення компетенції, який задається функцією Гауса (рис.2.22).

Вид однієї з поверхонь, що характеризує залежність вихідної змінної від двох (з сорока восьми) вхідних змінних наведено на рис.3.21.

Залежність «вхід-вихід» є важливою компонентою у схемі управління індивідуалізованим навчанням [22].



Рисунок 3.21 - Графічний вид залежності вихідної змінної від двох вхідних

Підхід, що запропоновано, пов'язаний із реалізацією обробки матриці коефіцієнтів інтеграції з метою формування нечітких правил продукцій для визначення інтеграцій, які найбільш доцільно сприяють формуванню відповідних компетенцій.

### **3.5 Кластеризація гомогенних груп осіб, що навчаються**

Поширення різноманіття управляючих впливів, з одного боку, нові можливості щодо врахування особливостей та здібностей учнів при формуванні груп (навіть віртуальних) – з другого, обумовлюють актуальність розгляду питання моделей та їх реалізацій для визначення груп осіб, що навчаються, як об'єкту управління в АСУ-Н.

Дидактично обумовлено, що найбільш результативним є навчання особистості за індивідуально обумовленими цілями, для досягнення яких здійснюється відбір змісту навчання [5]. Тобто, визначення об'єкту управління в АСУ-Н за умов групового навчання, передбачає наявність автоматизованої процедури розподілу учнів до так званих гомогенних груп. Відомим є визначення конкретних значень двох параметрів діагностично заданої цілі навчання (рівня засвоєння, ступеня абстракції) в залежності від групи діяльності за Шпрангером [23], інтелектуального компоненту за Гарднером [24]. В наступний час визначають вісім компонент діяльності,

вісім різних форм інтелекту. Таблиця цілей навчання [12] наведена у табл. В1.

Визначення зазначених характеристик особистості здійснюється на основі обробки результатів спеціальних тестів. Результатом тестування, як правило, є певна кількість балів. В залежності від цієї кількості визначається схильність до діяльності або переважна інтелектуальна компонента.

Аналіз особливостей розподілу учнів на гомогенні групи, співвіднесення його із відомими інтелектуальними засобами розв'язання задач групування або кластеризації, дозволяють обрати в якості найбільш доцільного інструментарію розв'язку даної задачі використання нейронних мереж, що самоорганізуються. Властивість самоорганізації є однією з найбільш привабливих властивостей нейронних мереж. Такою властивістю притаманна нейронній мережі, що запропоновано Т. Кохоненом [25]. Нейронні мережі, що самоорганізуються, можуть бути навченими визначеною групою (кластерами) векторів входу, які мають деякі спільні властивості.

Розрізняють мережі з невпорядкованими нейронами, які називають шарами Кохонена, та мережі з впорядкованими нейронами, які називають картами Кохонена. Кількість нейронів в мережі визначається кількістю класів. Так як в постановці даної задачі впорядкування даних не передбачається в зв'язку з особливістю вимірювання відповідних характеристик, то далі будемо розглядати саме шар Кохонена [2], архітектуру якого показано на рис. 3.22.

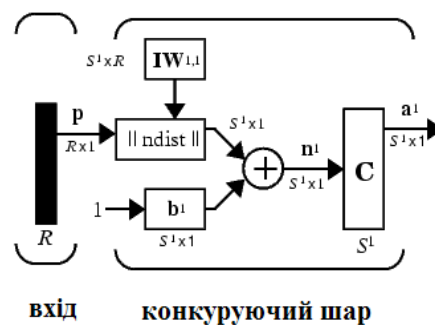


Рисунок 3.22 - Архітектура шару Кохонена

Шар Кохонена – це шар конкуруючого типу, оскільки в ньому застосовано конкуруючу функцію активації. Конкуруюча функція активації аналізує значення елементів вектора  $n'$  та формує виходи нейронів, які дорівнюють 0 для всіх нейронів, крім одного – переможця, який має на вході найбільше значення. Функція активації описується таким чином:

$$a_i^1 = \begin{cases} 1, i = i^*, i^* = \arg(\max n_i^1) \\ 0, i \neq i^* \end{cases} \quad (3.20)$$

Постановка задачі. Необхідно спроектувати та навчити мережу для розподілу учнів на групи за результатами психологічного тестування, що виражається двома чисельними значеннями. Сформуємо та навчимо мережу для розподілу на 8 класів масиву з двоелементних векторів. Припущення полягає в тому, що вектори характеристик є двоелементними. Це зроблено для можливості надання графічної інтерпретації. Зауважимо, що, наприклад, для вищої освіти, діяльна компонента визначена, єдина для кожної спеціальності.

Формування мережі. Для формування мережі застосуємо М-функцію `newsc`, яка входить в склад `Neural Network Toolbox` пакету `Matlab`.

Вхідні данні є масивом, який формується, як правило, засобами електронних таблиць. Тому імпортування даних з `Excel` до `Matlab` здійснюється з використанням функції інтерфейсу `putmatrix(P)`. Матриця `P` має наступну розмірність: рядків – 2, стовбців – за кількістю учнів. Припустимо, що кількість учнів – 72 особи. При формуванні шару Кохонена задаються наступні параметри:

`net=newsc(PR, S, KLR, CLR),`

де `PR` –  $R \times 2$  матриця мінімальних та максимальних значень для  $R$  вхідних елементів;

`S` – кількість нейронів;

`KLR` – швидкість навчання (за замовчуванням =0.01);

`CLR` – параметр швидкості налагодження (за замовчуванням =0.001).

Тоді, `net=newc([0 10; 0 5], 2);`

Початкові значення елементів матриці ваг знаходяться як центри інтервалів вхідних значень за допомогою функції `midpoint`. Перевірка може бути здійснена таким чином:

`wts=net.IW{1,1}.`

Характеристики мережі можна отримати за допомогою:

`net.layers{1}.`

Характеристики зміщень можна отримати за допомогою:

`net.biases{1}.`

Таким чином, мережу сформовано. Однак, зараз треба її навчити розв'язанню задачі кластеризації даних. Кожний нейрон блоку `compnet` конкурує за право відповіді на вектор входу. Якщо всі зміщення дорівнюють 0 у нейрона, вага якого найбільш близька до вектора входу, то цей нейрон одержує перемогу, повертає на виході значення 1, всі інші – 0.

Навчання шару Кохонена. Навчання здійснюється за правилом Кохонену, яке полягає в налагодженні елементів матриці ваг[2]:

$$IW_{i,j}^{1,1} \leftarrow IW_{i,j}^{1,1} + \alpha \left( I_{i,j} - IW_{i,j}^{1,1} \right) \quad (3.21)$$

Це рекурентне співвідношення забезпечує корегування рядка  $i$  матриці ваг шляхом додавання зваженої різниці вектора входу і значення рядка на попередньому кроці. Налагодження параметрів мережі за правилом Кохонена реалізовано у вигляді М-функції `learnk`.

Задаємо навчання на протязі 500 циклів:

`net.trainParam.epochs=500;`

`net=train(net,P);`

`w=net.IW{1}`

`bn=net.b{1}`

`cn=exp(1)/bn`

Отримуємо наступні результати навчання:

```

TRAINR, Epoch 0/500
TRAINR, Epoch 25/500
TRAINR, Epoch 50/500
TRAINR, Epoch 75/500
TRAINR, Epoch 100/500
TRAINR, Epoch 125/500
TRAINR, Epoch 150/500
TRAINR, Epoch 175/500
TRAINR, Epoch 200/500
TRAINR, Epoch 225/500
TRAINR, Epoch 250/500
TRAINR, Epoch 275/500
TRAINR, Epoch 300/500
TRAINR, Epoch 325/500
TRAINR, Epoch 350/500
TRAINR, Epoch 375/500
TRAINR, Epoch 400/500
TRAINR, Epoch 425/500
TRAINR, Epoch 450/500
TRAINR, Epoch 475/500
TRAINR, Epoch 500/500
TRAINR, Maximum epoch reached.

```

w =		bn =		cn =	
6.8598	2.8488	21.9838		0.1236	
1.4085	1.8876	21.5708		0.1260	
6.4505	1.0151	22.0933		0.1230	
3.7464	1.7159	21.6508		0.1256	
0.3324	1.7067	21.9630		0.1238	
7.6415	2.6484	22.0523		0.1233	
5.1896	1.5562	21.3244		0.1275	
5.8339	3.6407	21.3631		0.1272	

Як показують таблиці, центри кластеризації визначились за розподілом по восьми областям (рис.3.23), центри показано кружечками.




Рисунок 3.23 - Результати кластеризації гомогенних груп  
Виконаємо моделювання мережі після навчання:

$a = \text{sim}(\text{net}, p);$

$ac = \text{vec2ind}(a).$

За результатами кластеризації вхідного потоку розподіл учнів по гомогенним групам показано на діаграмі (рис.3.24):




Рисунок 3.24 - Діаграма розподілу учнів по гомогенним групам

Відхилення параметрів активності нейронів, що містяться в матриці  $sn$ , показано на рис.3.25.

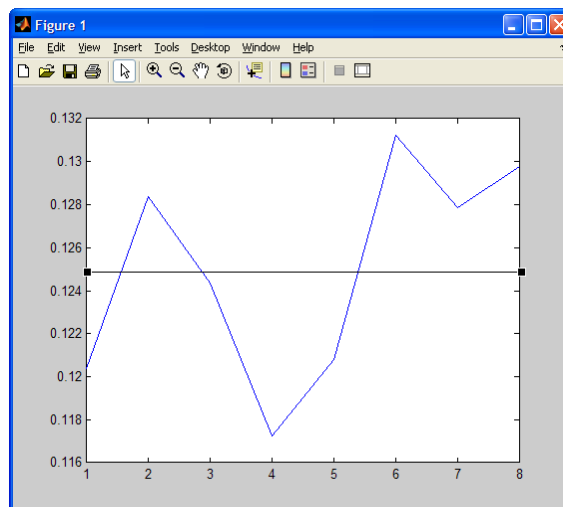


Рисунок 3.25 - Графік відхилень параметрів активності нейронів

Таким чином, сформовано, проведено навчання та показано на прикладі використання шару Кохонену для розв'язання задачі розподілу учнів на гомогенні групи за двома характеристиками. В моделі синергетичного управління вектор інтелекту враховує такі показники, як пам'ять та швидкість умовиводу. Критерії розподілу та засоби їх визначення мають властивість змінюватись згідно результатам психолого-педагогічних

досліджень, але даний метод дозволяє автоматизувати процес виявлення гомогенних груп, як об'єкту управління в АСУ-Н.

До переваг використання шару Кохонена є можливість навчання мережі без «вчителя» за рахунок самоорганізації, що є доцільним в системі автоматизованого управління навчанням. Крім того, слід зазначити, що деякі з параметрів учнів можуть змінюватись в часі, тому для здійснення динамічного перерозподілу на групи використання даного методу є доцільним та зручним.

### **3.6 Еволюційна оптимізація часу навчання**

Здійснення процесу навчання є послідовність цілеспрямованих дій щодо вивчення навчальних елементів в певній послідовності. Така послідовність має вигляд множини навчальних блоків, що складаються за моделлю, яка розглянута в п.2.3. Таким чином утворюються множини нечітких спрямованих графів. Врахування міжпредметних зв'язків здійснюється на основі моделі, що розглянута в п. 2.4.

Однак, багатоваріантна можливість взаємного розташування навчальних блоків, узгодженість їх за між предметними зв'язками, постають актуальним питання оптимізації часу, як потрібного ресурсу для здійснення процесу навчання. Таким чином, задача формування траєкторії навчання є оптимізаційною задачею. Визначимо постановку такої задачі та метод її розв'язку.

Постановка задачі оптимізації послідовності навчальних блоків за часом.

Як відомо, для формулювання оптимізаційної задачі необхідно ідентифікувати залежність

$$Y = F(X, Z), \quad (3.22)$$

де  $X = \langle x_1, x_2, \dots, x_n \rangle$  - вектор вхідних змінних, який характеризує властивості зовнішнього середовища, яке здійснює вплив на функціонування моделі;

$Z = \langle z_1, z_2, \dots, z_r \rangle$  - вектор внутрішніх змінних, який характеризує стан окремих елементів моделі;

$Y = \langle y_1, y_2, \dots, y_m \rangle$  - вектор вихідних змінних, який характеризує властивості моделі в цілому та визначає ступінь виконання її призначення.

В сучасних умовах одним з найбільш критичних ресурсів при навчанні є час. Тому найкраща послідовність навчальних елементів (блоків) визначається за критерієм потрібного часу. При цьому необхідно врахувати логічно обумовлені внутрішні та між предметні зв'язки. Для зручності призначимо за одиницю часу в даній постановці задачі час, що потрібний на вивчення одного навчального елемента, як константу -  $\tau$ .

Така задача має аналогію з відомою задачею комівояжера, метод розв'язку якої полягає в повному переборі всіх варіантів. Задовільні результати дає метод віток і меж [26], метод послідовного аналізу варіантів [27], пошук оптимального шляху за допомогою нейронної мережі Хопфілду [28]. Однак, за допомогою останнього методу оптимальний варіант отримують приблизно тільки в 50% обчислень, точність перших методів також не є високою, що визначається ймовірним попаданням в локальні оптимуми [29]. Тому в якості базового методу оптимізації розглянемо еволюційний метод визначення траєкторії, оптимізованої за часом навчання.

Складові елементи моделі (3.22) мають наступний опис:

$Y$  - час, що потрібний на вивчення  $x$  навчальних блоків;

$X$  - вектор, що задає структуру навчальних блоків (кількість, розподіл кількості НЕ в кожному з блоків);

$Z$  - вектор, який визначає взаємозв'язки внутрішні між НБ та між предметні (описуються відповідними матрицями).

Для ідентифікації залежності (3.22) розглянемо основні міркування для обчислення цільової, або fitness-функції. На основі загальних розсудів можна визначити наступну залежність:



$$Y = \sum_{i=1}^m \sum_{j=1}^{m_i} m_{ij}, \quad (3.23)$$

де  $m$  - кількість навчальних блоків,

$m_j$  - кількість навчальних елементів в  $j$ -му блоці.

Однак, при цьому не враховуються наступні особливі ситуації, які впливають на розрахунок часу при вивченні двох навчальних дисциплін – припустимо, НД1, НД2. Визначимо три такі ситуації:

Ситуація 1. Послідовне вивчення двох блоків. Позначимо НБ1 – навчальний блок, що відноситься до НД1, НБ2 – до НД2. Початок вивчення НБ2 точно співпадає з завершенням вивчення НБ1 (рис.3.26 а). Тоді формула (3.23) має вигляд:

$$Y_{12} = m_1 + m_2. \quad (3.24)$$

Ситуація 2. За рахунок міжпредметних зв'язків деякі навчальні елементи вивчаються одночасно (в межах одного навчального блоку), при цьому час вивчення скорочується. В цьому випадку формула (3.23) дещо змінюється (рис. 3.26 б):

$$Y_{12} = m_1 + m_2 - \Delta_{12}, \quad (3.25)$$

де  $\Delta_{12}$  - час, за який водночас вивчаються навчальні елементи з НБ1, НБ2.

Зауважимо, що це значення є сумарним по блоку в цілому, може складатись з декількох відрізків часу.

Ситуація 3. Між закінченням вивчення НБ1, початком вивчення НБ2 є деякий проміжок часу. Це негативно впливає на час засвоєння, оскільки має місце забування матеріалу НБ1. Тоді формула (3.23) потребує наступного уточнення:

$$Y_{12} = m_1 + m_2 + \Delta_{12}, \quad (3.26)$$

де  $\Delta_{12}$  - час, який додатково потрібно витратити для реалізації міжпредметних зв'язків. В загальному випадку між вивченням блоків НБ1, НБ2 може здійснюватись вивчення  $p$  блоків (рис.3.26 в). Для врахування

«штрафу» за розрив між взаємопов'язаними НБ введемо коефіцієнт розриву  $\zeta$ , який збільшується в залежності від кількості блоків  $p$ . Тоді:

$$\Delta_{12} = \sum_{i=1}^p n_i \zeta_i, \quad (3.27)$$

де  $i$  - номер блоку розриву.

Узагальнюючі всі три ситуації, отримаємо уніфіковану формулу для визначення часу вивчення двох НБ, між якими є міжпредметний зв'язок:

$$Y_{12} = m_1 + m_2 - \Delta_{12}, \quad (3.28)$$

$$\text{де } \Delta_{12} = \begin{cases} 0, \text{ якщо } K_1 \cap K_2 = \emptyset; \\ \sum_{i=1}^n \Delta_i, \text{ якщо } K_1 \cap K_2 \neq \emptyset; \\ -\sum_{i=1}^p n_i \zeta_i, \text{ якщо } |Y_{n_2} - Y_{n_1}| > 0, \end{cases}$$

де  $l_1, l_2$  - кількість навчальних елементів відповідно у блоках  $m_1, m_2$ .

Отже, вектор  $Z = \{Z_1, Z_2\}$ , де  $Z_1$  визначає вектор, що задає можливі варіанти послідовностей навчальних елементів, що утворюють відповідні НБ на основі матриці суміжності графа змісту;  $Z_2$  - визначає матрицю міжпредметних зв'язків. Зазначимо, що вектор  $Z_1 = \{z_i | \rho_i + 1 \geq \rho_i\}$ , де  $\rho_i$  - локальні ступені  $i$ .

Графічна інтерпретація можливих ситуацій розташування термінів навчання блоків НБ1 та НБ2 наведено на рис.3.26.




Рисунок 3.26 – Основні випадки взаємного розташування термінів вивчення навчальних блоків НБ1, НБ2

Для подальшого застосування матриці  $Z_2$  в моделі (3.22) необхідно виконати наступні перетворення:

1. На основі матриці міжпредметних зв'язків  $M = \|\mu_{kij}\|$  перейти до бінарної матриці  $M^* = \|m_{ij}\|$  на основі формули перетворення:

$$m_{ij} = \begin{cases} 1, & \text{якщо } \mu_{kij} > 0, \\ 0, & \text{в протилежному випадку.} \end{cases} \quad (3.29)$$

2. Матрицю  $M^*$  перетворити на матрицю  $T = \|t_{ij}\|$  ущільнення часу вивчення взаємопов'язаних НЕ:

$$t_{ij} = \Delta_{ij}, \quad (3.30)$$

де  $\Delta_{ij}$  визначається за (3.28).

Враховуючи (3.24) – (3.30), отримуємо вираз для знаходження часу потрібного для вивчення будь-яких двох НБ:

$$Y_{i,i+1} = m_i + m_{i+1} - \Delta_{i,i+1}. \quad (3.31)$$

Тоді, для вивчення  $m$  НБ, отримуємо наступний вираз fitness-функції:

$$Y = \sum_{i=1}^{m-1} Y_{i,i+1} \rightarrow \min. \quad (3.32)$$

Оптимізацію задачі пошуку необхідно провести відповідно до обмежень, що задані векторами послідовностей вивчення НБ з різних НД -  $Z_1 \in E1$ ,  $Z_2 \in E2$  та матрицею міжпредметних зв'язків  $M$ .

Таким чином, fitness-функція (або функція виживання) визначається як результат наступної залежності:

$$Y = F(E1, E2, m, Z_1 \in E1, Z_2 \in E2, M). \quad (3.33)$$

Для розв'язання оптимізаційної задачі (3.32) необхідно поряд із fitness-функцією сформулювати вибірккову сукупність, яка складається з множини векторів  $X_1, X_2, \dots, X_p$ , де  $p$  - кількість ненульових елементів матриці формування векторів інтеграції. Згідно з теорією генетичного алгоритму визначено відповідні терміни. Хромосома є вектором з вибіркової сукупності. Кожна хромосома має структуру бінарної строки (рис.3.27):

1	0	1	0	1	1	0	...	0	0	0	1	0	1	0	1	...	1
0	1	1	0	0	1	0	...	0	0	1	0	0	1	0	0	...	0
1	0	1	0	0	0	1	...	0	0	1	1	0	1	0	1	...	0
1	0	0	1	0	1	0	...	0	0	1	1	0	0	1	0	...	0
0	0	1	0	1	1	0	...	0	0	1	0	0	1	0	0	...	0
1	0	1	1	1	0	0	...	0	0	1	1	0	1	1	1	...	0

Рисунок 3.27 - Структура набору хромосом

Кожна хромосома  $X_i | i = \overline{1, p}$  складається з  $n$  біт – генів, причому  $l_1 + l_2 = n$ . Кожен ген відповідає наявності (1) або відсутності (0) в змісті навчання відповідного НБ. Крім того, позиція або локус  $X_i \in \bigcup_{j=\overline{1, n}}$  визначає номер НБ за порядком в траєкторії навчання. Враховуючи, що звичайні переборні варіанти пов'язані зі значними ресурсними витратами, генетичний алгоритм є найбільш доцільним засобом оптимізації даної постановки задачі [30].

Мета оптимізації: знайти таку послідовність хромосом, яка для усього набору (при формуванні СКМП) забезпечує мінімальний час навчання при обмеженнях, що обумовлені внутрішніми та міжпредметними зв'язками.

#### Основні параметри ГА:

1. Чисельність популяції – потужність безлічі рішень  $p$  визначається кількістю ненульових елементів матриці формування векторів інтеграції, що змістовно відповідає кількості пар між НД при низхідному застосуванні ГА (від формування КМП).

2. Довжина бінарного кодування (довжина генотипу) визначається як сума кількості структурних утворень (НБ або НЕ) з різних НД:  $n$ .

3. Кількість рішень, що генерується на кожній ітерації співпадає з чисельністю популяції -  $p$ .

4. Ймовірність використання оператора локальної зміни рішень (мутації)  $p_m = 0,001$ .

5. Метод селекції - турнірний [9], т. я. він на відміну від методу рулетки є ефективним саме в задачах мінімізації, а також дозволяє запобігти передчасній збіжності алгоритму. При турнірній селекції всі особи популяції розділяються на підгрупи з подальшим вибором в кожній з них особи з найкращою пристосованістю на основі детермінованого вибору (з ймовірністю 1).

6. Тип оператора глобального пошуку (кросовера) – одноточковий кросовер з детермінованим локусом в батьківських хромосомах. Це пов'язано з структурою хромосоми, яка визначена специфікою задачі, тобто позиція локусу  $j^* = l_1 + 1$ , якщо утворення хромосоми починається з НБ1.

7. Тип оператора локальної зміни (мутації) – ймовірний двоступеневий: спочатку визначається випадковим чином хромосома для мутації, потім випадковим чином визначається локус, ген якого піддається зміні на протилежне (0 на 1 та навпаки). Ймовірність мутації на основі практичних рекомендацій, що підтверджені комп'ютерними експериментами, обрано  $p_m = 0,001$ .

8. Процедура відбору – елітарна стратегія. Такий метод обрано тому, що практичне моделювання засвідчило переваги саме елітного відбору, т. я. саме за таким методом не губляться оптимальні вектори-рішення [29]. Зі всіх видів відбору тільки для елітного теоретично доказано, що ітераційний процес пошуку оптимального рішення сходиться. Елітна стратегія гарантовано залишає хромосому з найменшим значенням функції пристосованості в нову популяцію.

9. Критерій завершення процесу пошуку оптимального рішення є виконання однієї з наступних умов:

- досягнення необхідного значення fitness-функції (орієнтовне значення може бути визначено на основі прогнозування, за розсудом експертів або на основі аналізу статистичних даних);
- вибіркова популяція складається з однакових елементів;

– для любого значения  $\varepsilon > 0: |Y_i - Y_j| < \varepsilon, \forall i, j, i \neq j$ .

Блок-схема модифікованого генетичного алгоритму з визначеними параметрами наведено на рис. 3.28.

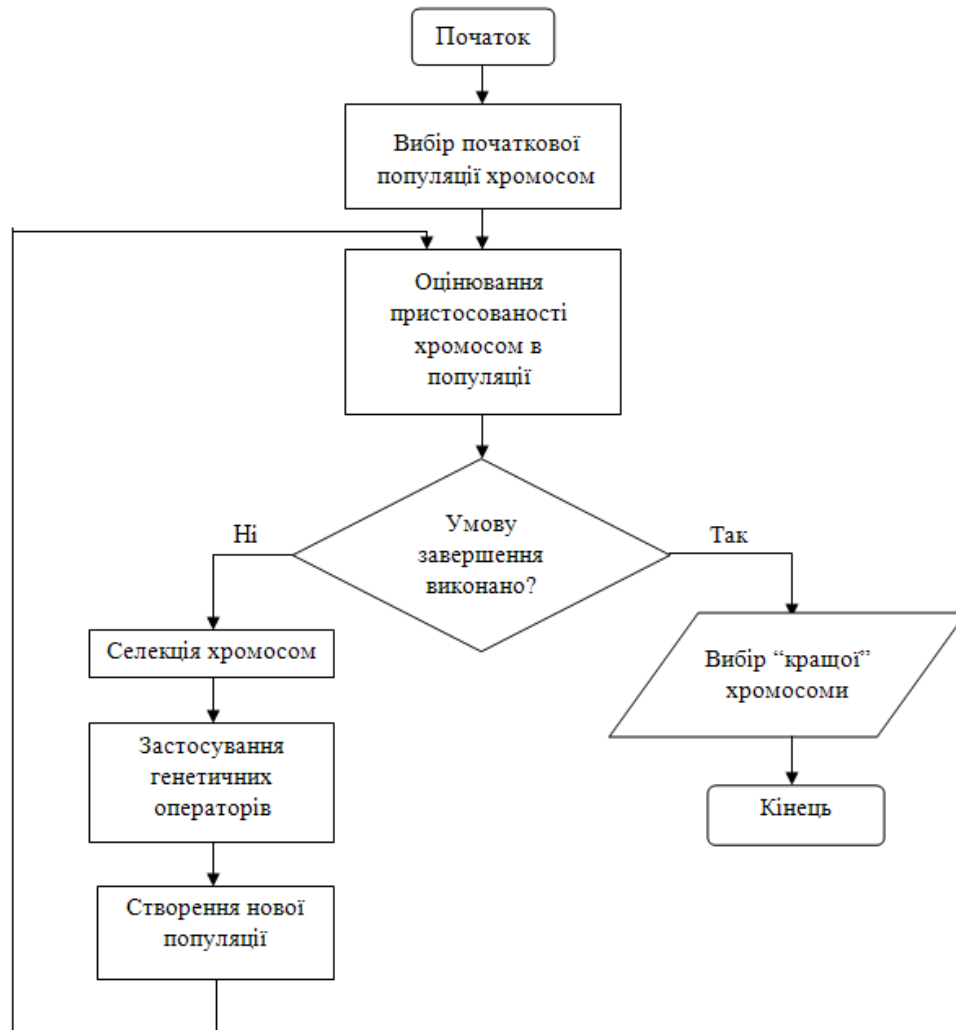


Рисунок 3.28 - Блок-схема ГА

Реалізація ГА. На основі співставлення основних параметрів ГА з особливостями інструментарію найбільш вживаних пакетів прикладних програм з засобами оптимізації, для проведення комп'ютерних експериментів по налагодженню параметрів було обрано програмний продукт FlexTool [31].

Тестовий приклад, що підтверджує працездатність запропонованого методу з визначеними параметрами, проводився на наступних даних:

Розмірність популяції =15;

ймовірність кросоверу=0.7;

ймовірність мутації=0.001;

довжина хромосоми=20 (10 від НБ НД1, 10 від НБ НД2).

Таким чином, найкраще рішення шукається в просторі рішень, що складається з  $20!$  можливих перестановок.

В умові завершення ГА використовується наближене значення нижньої границі мінімального часу вивчення зазначених двох блоків («Основні етапи складання частотного словника» навчальної дисципліни «Лексикографія», «Функції роботи з текстом в Excel» навчальної дисципліни «Інформаційні технології» для формування компетенцій автоматизованого складання частотного словника) на основі досвіду викладачів без врахування можливого ущільнення часу за рахунок міжпредметних зв'язків:  $Y_{\min} = 8$  академічних годин, що приблизно відповідає часу вивчення 16 навчальних елементів.

Результати, що отримані під час комп'ютерного експерименту наведено на рис.3.29.




Рисунок 3.29 - Результати роботи ГА з мінімізації часу навчання

Аналіз отриманих результатів підтвердив доцільність використання ГА з визначеними шляхом комп'ютерних експериментів параметрами для оптимізації траєкторій навчання у вигляді послідовності НЕ за часом. Зазначимо, що даний підхід може бути застосованим для інших видів ресурсів, яких потребує навчання.

Враховуючи модель процесів накопичення та дисипації знань, доцільно врахувати у формулі визначення часу (3.32) індивідуальні характеристики, зокрема коефіцієнт гіпотези забування  $\gamma$  (2.9), який характеризує залежність зростання потрібного часу для засвоєння певних НЕ від розриву часу між вивченням взаємозв'язаних із ними НЕ.

Отже, сформовано модель оптимізації часу навчання та її реалізація засобами ГА з експериментально визначеними параметрами. До особливостей моделі слід віднести можливість врахування системи як внутрішніх, так і міжпредметних зв'язків в умовах компетентнісного підходу.

Найбільш доцільним є використання даного методу на етапі аналізу процесу навчання перед прийняттям рішень щодо управління засобами відповідної АСУ-Н в залежності від рівня змісту матеріалу, що засвоюється. Схема застосування оптимізаційного ГА – є спадною (від рівня СКМП до рівня НБ). В той час, як обчислення кількості підрядних навчальних елементів для визначення основних компонентів (3.32) здійснюється навпаки – «знизу - догори» від рівня НЕ.

Але для всебічного аналізу ефективності процесу навчання, та вироблення на його основі управляючих впливів, крім інформації щодо ресурсів, необхідним є визначення ступеня досяжності цілі навчання.

Тому розглянемо задачу ідентифікації ступеня сформованості СКМП, як діагностично визначеної цілі навчання на основі системи нечіткого логічного висновку.



### 3.7 Ієрархічна система нечіткого логічного висновку для визначення ступеня сформованості СКМП

Управлінський аспект важливості вдосконалення системи встановлення рівня досяжності компетенції полягає в тому, що під час здійснення навчання необхідною є поточна інформація щодо результативності навчання, як основа для формування управлінських впливів з боку АСУ-Н, так і для інформування особи, що навчається з метою визначення коректив для покращання результативності навчання.

У зв'язку з тим, що діагностично визначена ціль навчання є вектором (2.40) із різнорідними даними, аналітичний вираз впливу яких на ступінь сформованості системи КМП, не встановлений, то розглянемо в якості інструменту формування інтегральної оцінки систему нечіткого логічного висновку.

Розглянемо основний елемент визначення результативності навчання НЕ. Загальний вигляд моделі багатомірної залежності «вхід-вихід» можна визначити наступним чином:

$$Y = F(x_1, x_2, x_3, x_4, x_5), \quad (3.34)$$

де  $Y = C$  - показник ступеня досяжності цілі навчання;

$x_1 = U$  - рівень засвоєння НЕ;

$x_2 = A$  - показник ступеня абстракції НЕ;

$x_3 = V$  - показник ступеня усвідомлення засвоєння НЕ;

$x_4 = K_3$  - коефіцієнт засвоєння НЕ;

$x_5 = K_H$  - коефіцієнт навички засвоєння НЕ.

Якщо визначити для лінгвістичної оцінки змінних використовувати по чотири терми, то максимальна кількість правил для надання залежності (3.34) за допомогою однієї бази знань буде складати  $4^5 = 1024$ . Тому доцільно використати ієрархічну базу знань з міркувань компактності. Крім того, застосування ієрархічної нечіткої бази знань дозволяє подолати «прокляття

розмірності». Це обумовлене тим, що в оперативній пам'яті людини може водночас зберігатись не більш ніж  $7 \pm 2$  понять-признаків [32]. Тому представимо модель системи (3.34) за допомогою трьох баз знань, які описують залежності  $y_1 = f_1(x_4, x_5)$ ,  $y_2 = f_2(x_1, x_2)$ ,  $Y = f_3(y_1, y_2, x_3)$  (рис.3.30).




Рисунок 3.30 - Ієрархічна система нечіткого логічного висновку

Для бази знань, що описує ту ж залежність, максимальна кількість правил буде складати:  $4^2 + 4^2 + 4^3 = 96$ , для адекватного опису зазвичай достатнім є 2-3% від загальної кількості, тобто 20-30 правил [2].

Застосуємо лінгвістичні змінні за 4 рівнями:  $x_4, x_5$  - початковий (ПЧ), середній (СР), достатній (ДС), високий (ВС);  $x_1, x_2$  - 1, 2, 3, 4;  $x_3$  - 0, 1, 2, 3. Оскільки ці показники мають якісний характер, то при оцінюванні показників експерт може тільки на інтуїтивному рівні оцінити його рівень. Тому застосуємо відомий принцип термометру [33] в оцінці якісних змінних. Зручність цього підходу полягає в тому, що він дозволяє розглядати різні за природою лінгвістичні змінні на єдиній універсальній множині  $U = [u, \bar{u}]$  (рис.3.31).




Рисунок 3.31 - Оцінка змінної  $u$  за принципом термометру

Рекомендації по оцінюванню часткових показників допомагають знизити суб'єктивність оцінки, розробляються з урахуванням дидактичних міркувань [5].

Припустимо, що лінгвістичні змінні  $x_1 \div x_5$ ,  $Y$  оцінюються нечіткими термами: початковий (ПЧ), середній (СР), достатній (ДС), високий (ВС), які визначені за допомогою функцій належності (рис.3.32).




Рисунок 3.32 - Функції належності нечітких термів

При нечіткому висновку за ієрархічною базою знань процедури дефазифікації і фазифікації для проміжних змінних  $y_1, y_2$  не виконуються. Результат логічного висновку  $y$  вигляді нечіткої множини напряму передається в машину нечіткого висновку наступного рівня ієрархії.

Експертні лінгвістичні висловлення, що відображають зв'язок між факторами  $x_1 - x_5$  та ступенем досяжності цілі навчання  $Y$  надано в табл. 3.2.

Таблиця 3.2 Фрагмент бази знань

№п/п	$x_1$	$x_2$	$y_1$	$x_4$	$x_5$	$y_2$	$x_3$	$Y$
1	1	1	1	ПЧ	СР	ПЧ	0	СР
2	2	1	1	ВС	СР	СР	1	СР
...	...	...	...	...	...	...	...	...
20	4	4	4	ВС	ВС	ВС	3	ВС

На основі розширення інструменту Fuzzy Logic Toolbox шляхом створення двох процедур: визначення результату висновку за проміжною базою знань  $y$

вигляді нечіткої множини за формулою (3.35); передачі ступеня належності  $\mu_{d_j}(\tilde{y})$ ,  $j = \overline{1, m}$  в машину нечіткого висновку наступного рівня ієрархії.

$$\tilde{y} = \left( \frac{\mu_{d_1}(\tilde{y})}{\tilde{d}_1}, \frac{\mu_{d_2}(\tilde{y})}{\tilde{d}_2}, \dots, \frac{\mu_{d_m}(\tilde{y})}{\tilde{d}_m} \right), \quad (3.35)$$

де  $\mu_{d_j}(\tilde{y})$  - ступень належності результату нечіткому терму  $\tilde{d}_j$ ,  $j = \overline{1, m}$ ,  $m$  - кількість термів. В якості проміжної нечіткої системи використано систему нечіткого висновку Сугено [2]. Нечіткий висновок за ієрархічною базою знань здійснює функція hier\_evalfis.

Приклад. Знайдемо ступінь досягнення цілі навчання  $Y$ , якщо вхідні змінні мають наступні значення (табл.3.3):

Таблиця 3.3 Вхідні змінні

$x_1$	$x_2$	$x_3$	$x_4$	$x_5$
1	1	0	1	2
1	2	1	4	2

Для знаходження вихідної змінної використаємо наступну програму в системі Matlab:

```
fis_file_names={'y1.fis', 'y2.fis', 'Y.fis'};
tree_list=[2 2; 3 3];
prepare_tree(fis_file_names, tree_list)
X1=[1 1 0 1 2]
out1=hier_evalfis(X1, FIS-list, input_list, tree_list,1)
X2=[1 2 1 4 2]
out2=hier_evalfis(X2, FIS-list, input_list, tree_list,1)
[out1 out2]
```

В результаті отримуємо наступні значення вихідної змінної  $Y$ :

```
ans=
1,3602
```

2,4301

Таким чином, сформовано модель для визначення ступеня досяжності цілі навчання, досліджено засоби реалізації, проведено комп'ютерні експерименти щодо підтвердження працездатності даного підходу.

Отримано механізм визначення результативності навчання згідно вектору цілей, який дозволяє особам, що навчаються, оперативно прогнозувати навчальні досягнення в визначеннях не оцінок, а саме результативності; викладачеві дозволяє своєчасно контролювати результативність навчання; для АСУ-Н дозволяє отримувати інформацію щодо управлінських дій в межах синергетичної моделі .

### **Практичні завдання**

1. Підготувати вхідні данні для навчання нейромережі за зразком, що наведений у табл. 3.1. Виконати навчання нейромережі з використанням пакету Neural Networks Toolbox математичної системи Matlab.

2. Виконати графічну візуалізацію процесу навчання (див. рис. 3.3) та проаналізувати отримані результати.

3. Для фрагменту навчальної дисципліни сформувати множини методів, форм та засобів навчання, множину навчальних елементів. Побудувати структурну схему визначення типу ДС для обраного фрагменту. За допомогою редактору нечітких нейронних мереж ANFIS Editor виконати моделювання нейро-нечіткої мережі та здійснити її налагодження. Оцінити вплив зміни значень вхідних змінних на значення вихідних за отриманою поверхнею нечіткого висновку.

4. Спроекувати модель системи міжпредметних зв'язків у вигляді модифікованої нейронної мережі Хопфілда на основі застосування інструменту Neural Networks Toolbox (NNT) пакету Matlab. Виконати перевірку поведінки мережі при випадкових початкових умовах.

5. Визначити коефіцієнт інтеграції, що є необхідним для забезпечення потрібного рівня взаємозв'язків між заданими навчальними блоками двох обраних навчальних дисциплін. Проаналізувати отриманий результат для даних власної моделі.

6. Виконати імпорт даних з таблиці MS Excel для кластеризації в пакет Matlab. Знайти центри кластерів за допомогою метода субтрактивної кластеризації. Проаналізувати отримані результати.

7. На основі результатів, що отримані у завданні 6, згенерувати нечіткі правила для забезпечення ідентифікації взаємозв'язку між парами НД та ступенем досяжності відповідних компетенцій. При формуванні даних кластеризації застосувати освітньо-професійну програму підготовки бакалаврів за напрямком 0403 «Системні науки та кібернетика».

8. Визначити для групи осіб, що навчаються, з використанням набору тестів компонент діяльності за Шпрангером та форму інтелекту за Гарднером (див. табл. В.1). Тестування виконати за наступними тестами: для визначення особистості, на схильність до конфліктного поведіння (тест Томаса), тест на визначення інтересів особистості, вербальний тест Айзенка.

9. Спроекувати та навчити мережу для розподілу учнів за результатами психологічного тестування, що отримані в наслідок розв'язання завдання 8. Для формування мережі з шаром Кохонену застосувати інструмент Neural Network Toolbox пакету Matlab. Виконати навчання та моделювання мережі після навчання. Відобразити результати кластеризації за допомогою діаграми. Проаналізувати отримані результати. Які припущення мають місце в моделі розподілу?

10. Підготувати вхідні данні для розв'язання оптимізаційної задачі з пошуку стратегії навчання, яка відповідає мінімальному часу навчання при обмеженнях внутрішніх та міжпредметних зв'язків. Вхідні данні представити у вигляді бінарної строки, утвореної з ненульових елементів матриць формування векторів інтеграції. На основі застосування програми FlexTool

застосувати генетичний алгоритм та налагодити його параметри. Оцінити кількість застосованих поколінь для отримання оптимального розв'язку та рівень зменшення показника функції пристосованості.

### **Контрольні питання для самоперевірки**

1. Поясніть структуру нейронної мережі синергетичного управління навчанням. В яких випадках можливі зміни у структурі мережі, що розглядається?

2. За якими параметрами встановлюється тип монопредметної дидактичної системи? Порівняйте процедуру встановлення викладачем «ручним» засобом та за допомогою автоматизованої процедури. В чому відмінності, оцініть недоліки і переваги зазначених засобів.

3. Наведіть приклади правил продукцій для нейро-нечіткої моделі по визначенню типу ДС. Які з відомих Вам методів інженерії знань найбільш доцільні для отримання знань від викладачів-експертів для формування таких правил?

4. З яких основних кроків складається алгоритм функціонування мережі Хопфілду? В яких випадках мережа Хопфілда з довільного початкового стану приходить до стану стійкої рівноваги (атрактору)?

5. В чому проявляється аналогія між системою міжпредметних зв'язків та моделлю асоціативного мислення? Які припущення мають місце в застосуванні такої аналогії?

6. Яким чином можна здійснити перевірку мережі Хопфілда при випадкових початкових умовах?

7. Яким чином визначається кількість кластерів за вдосконаленим гірським алгоритмом субтрактивної кластеризації?

8. Поясніть послідовність здійснення екстракції нечітких правил в задачі нечіткої кластеризації взаємозв'язків між системами міжпредметних зв'язків та компетенцій. Оцініть розмірність кластеризації при складанні нової

навчальної дисципліни, нового робочого плану. В чому полягають переваги автоматизації цього процесу?

9. В чому полягає особливість архітектури шару Кохонена? Чому саме цю архітектуру доцільно використовувати для розподілу учнів на гомогенні групи? В яких формах навчання, на Вашу думку, найбільш доцільним є розподілення на групи саме таким засобом?

10. Поясніть переваги застосування генетичного алгоритму для розв'язання оптимізаційної задачі з пошуку стратегії з мінімальним часом. Які припущення мають місце в моделі оптимізації? Запропонуйте декілька варіантів усунення цих припущень або зменшення похибки, що отримана.

### **Теми для самостійного опрацювання**

1. Синергетичний метод управління складними організаційно-технічними системами.
2. Основні напрямки синергетики освіти.
3. Управління індивідуалізованим навчанням в дистанційному навчанні.
4. Автоматизація розподілу учнів по гомогенним віртуальним групам.
5. Особливості психологічного тестування в електронному навчанні.
6. Розробка структурно-функціональної схеми редактора міжпредметних зв'язків.

### **Література**

#### Основні джерела

1. Терехов В.А. Нейросетевые системы управления / В.А. Терехов. – М.: ВШ, 2002. – 183 с.
2. Медведев В.С. Нейронные сети. Matlab6 / В.С. Медведев, В.Г. Потёмкин. – М.: ДИАЛОГ-МИФИ, 2002. – 496 с.
3. Hagan M.T., Menhaj M. Training feedforward networks with the Marquardt algorithm // IEEE Transactions on Neural Networks. - 1994. - Vol.5. - , №6. - P.989-993.



4. Хайкин С. Нейронные сети: полный курс / С. Хайкин. – М.: Изд.дом «Вильямс», 2006. - 1104 с.
5. Беспалько В.П. Образование и обучение с участием компьютеров (педагогика третьего тысячелетия) / В.П. Беспалько. – М.: МПСИ, 2002. - 325 с.
6. Информатизация образования: направления, средства, технологии / под общ. ред. С.И. Маслова. – М.: Издательство МЭИ, 2004. – 868 с.
7. Brusilovsky P. Adaptive and Intelligent Web-based Educational Systems / P. Brusilovsky, C. Peylo // International Journal of Artificial Intelligence in Education. – 2003. -№13. - P.156–169.
8. Костюкова Т.П. Математическая модель обучаемого в электронных учебных курсах / Т.П. Костюкова, Е.И. Филосова // Новые технологии в образовании: научн.-техн. журнал. – Воронеж: Научная книга. – 2006. - №1. – С.105-107.
9. Рутковская Д. Нейронные сети, генетические алгоритмы и нечёткие системы / Д. Рутковская, М. Пилиньский, Л. Рутковский. – М.: Горячая линия – Телеком, 2006. – 452 с.
10. Леоненков А.В. Нечёткое моделирование в среде Matlab и fuzzyTEACH / А.В. Леоненков. – СПб.: БХВ – Петербург, 2003. – 736 с.
11. Мазурок Т.Л. Интеллектуальное построение автоматизированных дидактических систем / Т.Л. Мазурок // Education Technology & Society. – 2008. - №11(3). – С.368-374.
12. Самарин Ю.А. Очерки психологии ума / Ю.А. Самарин. – М.: Изд-во АПН РСФСР, 1962. – 268 с.
13. Гаврилов А.В. Модель ассоциативного мышления / А.В. Гаврилов // Системы искусственного интеллекта. – Новосибирск: НГТУ, 1993. – С.10-14.
14. Амосов Н.М. Стохастические нейроподобные сети с ассамблеевой организацией / Н.М. Амосов, Э.М. Куссуль, А.М. Касаткин, Л.М. Касаткина.

– Киев. – (Препринт / АН УССР. Ин-т кибернетики им. М.В. Глушкова), 1989. – 30 с.

15. Соколов В.Н. Нейронные механизмы памяти и обучения / В.Н. Соколов. – М.: Наука, 1981. – 144 с.

16. Кужель С.С. Информационные технологии – средство развития системного мышления / С.С. Кужель, О.С. Кужель // Educational Technology & Society. – 2002. - №5. – P.264-275.

17. Гаврилов А.В., Новицкая Ю.В. Архитектура «двухполушарной» экспертной системы // Межвуз. сб. «Кибернетика и ВУЗ. Интеллектуальные информационные технологии». – 1994. - вып. 28. – С.15-23.

18. Hopfield J. Neural Networks and physical systems with emergent collective computational abilities / J. Hopfield // Proceedings of the National Academy of Science, USA, 1982. – Vol.79. – P.2554-2558.

19. Штовба С.Д. Проектирование нечётких систем средствами Matlab / С.Д. Штовба. – М.: Горячая линия – Телеком, 2007. – 288 с.

20. Сетлак Г. Интеллектуальные системы поддержки принятия решений / Г. Сетлак. – К.: Логос, 2004. – 251 с.

21. Освітньо-професійна програма підготовки бакалавра напряму підготовки 0925 «Автоматизація та комп'ютерно-інтегровані технології». – К.: МОН України, 2004. – 36 с.

22. Мазурок Т.Л. Нейромережева реалізація інтелектуальної підтримки прийняття рішень в автоматизованому управлінні навчанням / Т.Л. Мазурок, Ю.К. Тодорцев // Системні дослідження та інформаційні технології. – 2011. - №3. – С.88-101.

23. Шпрангер Э. Психология личности. Тексты / Э. Шпрангер. – М., 1982.

24. Аткинсон Р.Л., Аткинсон Р.С., Смит Э.Е., Бем Д.Дж., Нолен-Хоэксеми С. Введение в психологию / под общ.ред. Зинченко В.П. Санкт-Петербург: Прайм-Евროзнак 2007.

25. Kohonen T. Self-Organization and Associative Memory. – Berlin: Springer-Verlag, 1987.
26. Новиков Ф.А. Дискретная математика для программистов / Ф.А. Новиков. – СПб.: Питер, 2002. – 304 с.
27. Павлов А.А. Алгоритмическое обеспечение сложных систем управления. – К.: Вища школа, 1989. -166 с.
28. Омату С. Нейроуправление и его приложения / С. Омату, М. Хадид, Р. Юсоф – М.: ИПРЖР, 2000. – 272 с.
29. Снитюк В.Е. Эволюционные технологии принятия решений при пожаротушении / В.Е. Снитюк, А.А. Быченко, А.Н. Джулай. – Черкассы: Маклаут, 2008. – 268 с.
30. Курейчик В.М. Теория и практика эволюционного моделирования / В.М. Курейчик. – Таганрог, 2003. – 432 с.
31. FlexTool, Flexible Intelligence Group, L.L.C., Tuscaloosa, AL35486-1477, USA.
32. Miller G.A. The Magic Number Seven Plus or Minus Two: Some Limits on Our Capacity for Processing Information // Psychological Review. – 1956. - №63. – P.81-97.
33. Мітюшкін Ю.І. Soft Computing: ідентифікація закономірностей нечіткими базами знань / Ю.І. Мітюшкін, Б.І. Мокін, О.П. Ротштейн. – Вінниця: УНІВЕРСУМ-Вінниця, 2002. – 145 с.

#### Допоміжні джерела

1. Ерёмкин А.И. Система межпредметных связей в высшей школе /А.И. Ерёмкин. – Харьков: ХГУ, 1984. – 151 с.
2. Федорец Г.Ф. Межпредметные связи в процессе обучения / Г.Ф. Федорец. – Л.: ЛПИ им. А.И. Герцена, 1985. – 87 с.
3. Максимова В.Н. Межпредметные связи в совершенствовании процесса обучения / В.Н. Максимова. – М.: Просвещение, 1987. – 147 с.

4. Когнитивное управление в интеллектуальных обучающих системах / А.Ф. Верлань, М.Ф. Ус, А.В. Пискун, В.А. Федорчук; под ред. А.Ф. Верлань. – Черкассы: ЧИУ, 2002. – 104 с.
5. Воробьёв А.В. Модель преодоления интервала междолжностных компетенций / А.В. Воробьёв // Educational Technology & Society. – 2006. - №9. – Р.260-264.
6. Когнитивное управление в интеллектуальных обучающих системах / А.Ф. Верлань, М.Ф. Ус, А.В. Пискун, В.А. Федорчук; под ред. А.Ф. Верлань. – Черкассы: ЧИУ, 2002. – 104 с.
7. Воробьёв А.В. Модель преодоления интервала междолжностных компетенций / А.В. Воробьёв // Educational Technology & Society. – 2006. - №9. – Р.260-264.
8. Кудрявцев В.Б. Моделирование процесса обучения / В.Б. Кудрявцев [и др.] // Интеллектуальные системы – 2006. – т.10. – вып.1-4. – С.189-270.
9. Рыбина Г.В. Обучающие интегрированные экспертные системы: некоторые итоги и перспективы / Г.В. Рыбина // Искусственный интеллект и принятие решений. – 2008. - №1. – С.22-46.
10. Гагарін О.О. Дослідження і аналіз методів та моделей інтелектуальних систем безперервного навчання / О.О. Гагарін, С.В. Титенко // Наукові вісті НТУУ "КПІ". – 2007. – № 6(56). – С. 37-48.
11. Рассел С. Искусственный интеллект. Современный поход / С. Рассел, П. Норвиг. - М.: Изд.дом «Вильямс», 2007. – 1408 с.

#### Internet-джерела

1. <http://aied.inf.ed.ac.uk/>
2. <http://aied.inf.ed.ac.uk/aiedsoc.html>
3. <http://ifets.ieee.org/russian/>
4. <http://www.aaai.org/>
5. <http://dict.linux.org.ua/>

## ДОДАТКИ

## Додаток А

Набір даних для нечіткої кластеризації

Таблиця А.1 – Матриця даних

X[I,1]	X[I,2]	X[I,3]	X[I,4]	X[I,5]	X[I,6]	X[I,7]	X[I,8]	X[I,9]	X[I,10]	X[I,11]	X[I,12]
0,64	0,21	0,61	0,64	0,21	0,61	0,64	0,21	0,61	0,64	0,21	0,61
0,60	-0,02	0,58	0,60	-0,02	0,58	0,60	-0,02	0,58	0,60	-0,02	0,58
0,59	0,17	0,49	0,59	0,17	0,49	0,59	0,17	0,49	0,59	0,17	0,49
0,51	0,19	0,39	0,51	0,19	0,39	0,51	0,19	0,39	0,51	0,19	0,39
0,38	0,14	0,58	0,38	0,14	0,58	0,38	0,14	0,58	0,38	0,14	0,58
0,39	0,24	0,42	0,39	0,24	0,42	0,39	0,24	0,42	0,39	0,24	0,42
0,61	0,06	0,64	0,61	0,06	0,64	0,61	0,06	0,64	0,61	0,06	0,64
0,50	0,09	0,58	0,50	0,09	0,58	0,50	0,09	0,58	0,50	0,09	0,58
0,63	0,09	0,32	0,63	0,09	0,32	0,63	0,09	0,32	0,63	0,09	0,32
0,49	0,13	0,30	0,49	0,13	0,30	0,49	0,13	0,30	0,49	0,13	0,30
0,72	0,31	0,87	0,72	0,31	0,87	0,72	0,31	0,87	0,72	0,31	0,87
0,59	0,24	0,47	0,59	0,24	0,47	0,59	0,24	0,47	0,59	0,24	0,47
0,49	0,32	0,54	0,49	0,32	0,54	0,49	0,32	0,54	0,49	0,32	0,54
0,46	0,03	0,54	0,46	0,03	0,54	0,46	0,03	0,54	0,46	0,03	0,54
0,56	0,21	0,45	0,56	0,21	0,45	0,56	0,21	0,45	0,56	0,21	0,45
0,51	0,38	0,48	0,51	0,38	0,48	0,51	0,38	0,48	0,51	0,38	0,48
0,66	0,25	0,66	0,66	0,25	0,66	0,66	0,25	0,66	0,66	0,25	0,66
0,65	0,30	0,56	0,65	0,30	0,56	0,65	0,30	0,56	0,65	0,30	0,56
0,51	0,04	0,57	0,51	0,04	0,57	0,51	0,04	0,57	0,51	0,04	0,57
0,79	0,24	0,59	0,79	0,24	0,59	0,79	0,24	0,59	0,79	0,24	0,59
0,41	0,33	0,62	0,41	0,33	0,62	0,41	0,33	0,62	0,41	0,33	0,62
0,55	0,31	0,46	0,55	0,31	0,46	0,55	0,31	0,46	0,55	0,31	0,46
0,44	0,21	0,43	0,44	0,21	0,43	0,44	0,21	0,43	0,44	0,21	0,43
0,87	0,18	0,47	0,87	0,18	0,47	0,87	0,18	0,47	0,87	0,18	0,47
0,41	0,25	0,45	0,41	0,25	0,45	0,41	0,25	0,45	0,41	0,25	0,45
0,48	0,21	0,48	0,48	0,21	0,48	0,48	0,21	0,48	0,48	0,21	0,48
0,50	0,37	0,57	0,50	0,37	0,57	0,50	0,37	0,57	0,50	0,37	0,57
0,65	0,21	0,44	0,65	0,21	0,44	0,65	0,21	0,44	0,65	0,21	0,44
0,67	0,10	0,39	0,67	0,10	0,39	0,67	0,10	0,39	0,67	0,10	0,39
0,81	0,16	0,53	0,81	0,16	0,53	0,81	0,16	0,53	0,81	0,16	0,53

## Додаток Б

Данні для кластеризації формування компетенцій

Таблиця Б.1 – Матриця коефіцієнтів інтеграції

	<b>D1</b>	<b>D2</b>	<b>D3</b>	<b>D4</b>	<b>D5</b>	<b>D6</b>	<b>D7</b>	<b>D8</b>	<b>D9</b>	<b>D10</b>
<b>D1</b>	0	0	0	0	0,3	0,3	0,5	0,3	0,3	0,5
<b>D2</b>		0	0,5	0,3	0	0	0,3	0,3	0,3	0,5
<b>D3</b>			0	0,5	0	0	0,3	0,3	0,3	0,5
<b>D4</b>				0	0	0	0,5	0,5	0,3	0,5
<b>D5</b>					0	0,3	0,2	0,2	0,3	0,2
<b>D6</b>						0	0,2	0,3	0,1	0,2
<b>D7</b>							0	0,7	0,2	0,5
<b>D8</b>								0	0,2	0,5
<b>D9</b>									0	0,3
<b>D10</b>										0

Таблиця Б.2 – Умовні позначення НД

Позначення	Назва НД
D1	Метрологія
D2	Технологічні вимірювання та прилади
D3	Технічні засоби автоматизації
D4	Електроніка та електромеханіка
D5	Електроніка та мікросхемотехніка
D6	Мікропроцесорна техніка
D7	Теорія автоматичного управління
D8	Виробничі процеси та обладнання об'єктів автоматизації
D9	Технічні засоби автоматизації
D10	Основи комп'ютерно-інтегрованого управління

## Додаток В

## Параметри діагностично заданої цілі навчання

Таблиця В.1 – Матриця цілей навчання

Діяльність за Шпрангером	Природнича	Економічна	Естетична	Соціальна	Політична	Релігійна	Індустріальна	Інформаційна
Інтелектуальний компонент за Гарднером	Цілі навчання ( <i>рівень засвоєння/ступінь абстракції</i> )							
Лінгвістичний	1/В	1/А	2/В	2/В	2/В	2/В	1/А	1/А
Музичний	1/А	-	2/В	1/А	1/А	2/В	-	1/В
Логіко-математичний	2/В	2/В	1/А	1/А	1/А	1/А	1/А	2/В
Просторовий	1/А	1/А	2/А	1/А	1/А	1/А	2/В	2/В
Кінестетичний	-	-	2/А	-	-	-	2/А	1/А
Міжособистісний	-	1/А	2/А	2/А	2/В	2/В	1/А	1/А
Суспільний	-	1/А	2/А	2/В	2/В	2/В	-	-
Прогностичний	2/В	2/В	1/А	2/В	2/В	1/А	2/В	2/В
Імаджінативний	2/В	2/В	2/А	2/В	2/В	1/А	2/А	2/В