

## ДОДАТОК А

Харківський національний університет радіоелектроніки

Кафедра КІТС

### **Застосування штучних нейронних мереж для побудови інтелектуального класифікатора**

Агестаційна робота

Другий (магістерський) рівень

Автор:

магістрантка гр. КІТМ-19-1

Звонкова В.О.

Керівник:

д.т.н., проф. каф. КІТС

Корабльов М.М.

1

## Актуальність

Сьогодні існує певний клас актуальних завдань, вирішення яких без використання штучних нейронних мереж неможливо або складно піддається реалізації.

Завдання класифікації – вказати належність вхідної вибірки, представленої вектором числових атрибутів, до одного або декількох визначених класів.

Нейронні мережі володіють властивістю вирішувати недоступні для традиційної математики операції обробки, порівняння, класифікації образів; здатністю до самонавчання та самоорганізації. Вони забезпечують діагностику, розпізнавання та класифікацію для складних просторових об'єктів з важко роздільними, нелінійними багатокласовими технічними станами.

Тому застосування нейромережевої технології класифікації надає можливість певною мірою зняти математичні проблеми аналізу властивостей системи. При цьому, якість розпізнавання більшою мірою буде залежати від властивостей нейромереж, а не від аналітично розрахованих правил прийняття рішення, що, зазвичай, реалізуються за допомогою комп'ютерних програм.

2

## Мета і задачі роботи

**Метою** магістерської атестаційної роботи є розробка інтелектуального класифікатора на основі нейронних мереж для аналізу даних та їх класифікації.

### **Задачі роботи:**

- ▶ провести аналіз методів класифікації;
- ▶ розглянути типи нейронних мереж;
- ▶ проаналізувати архітектури нейронних мереж;
- ▶ розробити класифікатор для діагностики стану об'єкта з використанням імовірнісної нейронної мережі;
- ▶ протестувати сформований класифікатор на розпізнавання стану об'єкту за допомогою тестових множин;
- ▶ провести оцінку ефективності класифікатора від параметру впливу, який характеризує розсіювання Гаусівського розподілу, та від кількості об'єктів навчальної множини;
- ▶ оцінити ефективність розпізнавання та встановити залежність показника правильності класифікації від параметру впливу НМ і кількості об'єктів навчальної множини.

3

## Методи класифікації

- ▶ Метод лінійної регресії.
- ▶ Байєсовська логістична регресія.
- ▶ Ранжування і чітка класифікація.
- ▶ Класифікація на основі штучних нейронних мереж та ін.

4

## Архітектури нейронних мереж

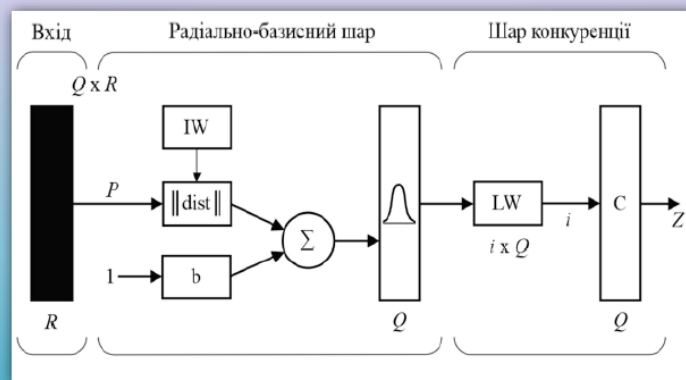
З точки зору принципів побудови НМ класифікуються в залежності від наявності або відсутності зворотних зв'язків:

- ▶ мережі прямого поширення сигналів без зворотних зв'язків;
- ▶ рекурентні мережі або мережі зі зворотними зв'язками.



5

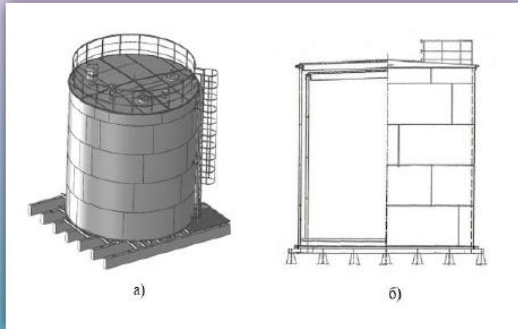
## Імовірнісна нейронна мережа



Архітектура ІНМ

6

## Об'єкт діагностики (класи S0-S5)


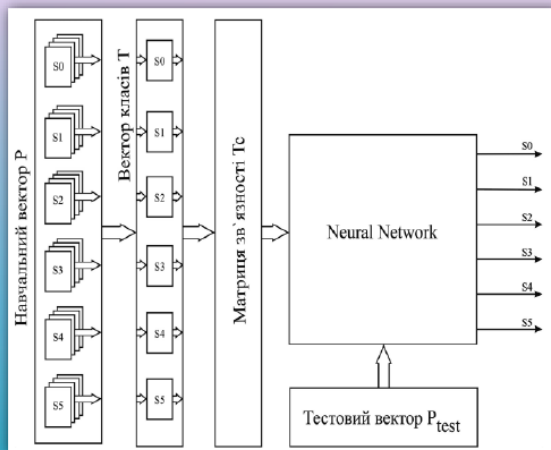


Резервуар для зберігання дизельного палива: а) геометрична тривимірна модель ; б) загальна схема конструкції

- **Клас  $S_0$**  – нормальне функціонування. ознаки вхідних множин не перевищують похибку  $\Delta = \pm 5\%$ .
- **Клас  $S_1$**  – вхідні вектори, один із параметрів яких перевищує похибку  $\Delta = \pm 5\%$ .
- **Клас  $S_2$**  – вхідні вектори, в яких одночасно два будь-які параметри перевищують похибку  $\Delta = \pm 5\%$ .
- **Класу  $S_3$**  – вхідні вектори, в яких одночасно три будь-які параметри перевищують похибку  $\Delta = \pm 5\%$ .
- **Клас  $S_4$**  – вхідні вектори, в яких одночасно чотири будь-які параметри перевищують похибку  $\Delta = \pm 5\%$ .
- **Клас  $S_5$**  – вхідні вектори, в яких одночасно всі параметри ознак перевищують похибку  $\Delta = \pm 5\%$ .

7

## Ініціалізація НМ класифікатора




Класифікатор технічного стану


Кількість навчальних векторів станів S0 – S5

8


Блок-схема класифікатора в програмному середовищі Matlab




Перший шар НМ



Другий шар НМ



Блок-схема сформованої НМ



ТОЧНІСТЬ КЛАСИФІКАЦІЇ ( $\delta = 2,5\%$ )

spread (вплив)	Стан	Коефіцієнт ефективності
	SO (1)	
<b>Nzag</b>	84	-
<b>1</b>	0	<b>0</b>
<b>0,8</b>	0	<b>0</b>
<b>0,6</b>	0	<b>0</b>
<b>0,4</b>	0	<b>0</b>
<b>0,3</b>	0	<b>0</b>
<b>0,2</b>	20	<b>0,24</b>
<b>Nzag</b>	84	-
<b>0,1</b>	65	<b>0,77</b>
<b>0,08</b>	82	<b>0,97</b>
<b>0,06</b>	84	<b>1</b>
<b>0,01</b>	84	<b>1</b>
<b>0,005</b>	84	<b>1</b>

ТОЧНІСТЬ КЛАСИФІКАЦІЇ ( $\delta = 6\%$ )

spread (вплив)	Клас						$\Sigma$	К
	SO (1)	S1 (2)	S2 (3)	S3 (4)	S4 (5)	S5 (6)		
<b>Nzag. тест</b>	22	10	20	20	10	2	84	-
<b>1</b>	0	0	20	0	0	0	20	<b>0,24</b>
<b>0,8</b>	0	0	20	0	0	0	20	<b>0,24</b>
<b>0,6</b>	0	2	20	2	0	0	24	<b>0,29</b>
<b>0,5</b>	0	4	18	8	0	0	30	<b>0,36</b>
<b>0,4</b>	0	6	16	14	0	0	36	<b>0,43</b>
<b>0,3</b>	0	8	20	18	6	0	52	<b>0,62</b>
<b>0,2</b>	12	10	20	20	10	2	74	<b>0,89</b>
<b>0,1</b>	22	10	20	20	10	2	84	<b>1</b>
<b>0,08</b>	22	10	20	20	10	2	84	<b>1</b>
<b>0,06</b>	22	10	20	20	10	2	84	<b>1</b>
<b>0,04</b>	22	10	20	20	10	2	84	<b>1</b>
<b>0,02</b>	22	10	20	20	10	2	84	<b>1</b>
<b>0,01</b>	22	10	20	20	10	2	84	<b>1</b>
<b>0,005</b>	22	10	20	20	10	2	84	<b>1</b>

ТОЧНІСТЬ КЛАСИФІКАЦІЇ ( $\delta = 9\%$ )

spread (вплив)	Клас						$\Sigma$	К
	S0 (1)	S1 (2)	S2 (3)	S3 (4)	S4 (5)	S5 (6)		
Нзар. тест	22	10	20	20	10	2	84	-
1	0	0	20	2	0	0	22	0.26
0.9	0	0	20	2	0	0	22	0.26
0.8	0	0	20	8	0	0	28	0.33
0.7	0	0	20	14	0	0	34	0.40
0.6	0	4	18	14	0	0	36	0.43
0.5	0	4	18	18	4	0	44	0.52
0.4	0	8	20	20	10	2	60	0.72
0.3	0	10	20	20	10	2	62	0.74
0.2	12	10	20	20	10	2	74	0.88
0.1	22	10	20	20	10	2	84	1
0.08	22	10	20	20	10	2	84	1
0.06	22	10	20	20	10	2	84	1
0.04	22	10	20	20	10	2	84	1
0.02	22	10	20	20	10	2	84	1
0.01	22	10	20	20	10	2	84	1
0.005	22	10	20	20	6	0	78	0.93

ТОЧНІСТЬ КЛАСИФІКАЦІЇ ( $\delta = 10\%$ )

spread (вплив)	Клас						$\Sigma$	К
	S0 (1)	S1 (2)	S2 (3)	S3 (4)	S4 (5)	S5 (6)		
Нзар. тест	22	10	20	20	10	2	84	-
1	0	0	20	4	0	0	24	0.29
0.9	0	0	20	8	0	0	28	0.33
0.8	0	0	20	12	0	0	32	0.38
0.6	0	4	18	16	2	0	40	0.48
0.5	0	4	18	20	6	0	48	0.57
0.4	0	10	20	20	10	2	62	0.74
0.2	12	10	20	20	10	2	74	0.88
0.1	22	10	20	20	10	2	84	1
0.08	22	10	20	20	10	2	84	1
0.06	22	10	20	20	10	2	84	1
0.04	22	10	20	20	10	2	84	1
0.02	22	10	20	20	10	2	84	1
0.01	22	10	20	20	10	2	84	1
0.005	22	10	20	20	10	2	84	1

ТОЧНІСТЬ КЛАСИФІКАЦІЇ ( $\delta = 12\%$ )

spread (вплив)	Клас						$\Sigma$	К
	S0 (1)	S1 (2)	S2 (3)	S3 (4)	S4 (5)	S5 (6)		
Нзар. тест	22	10	20	20	10	2	84	-
1	0	0	20	10	0	0	30	0.36
0.9	0	0	18	14	0	0	32	0.38
0.8	0	0	18	16	0	0	34	0.40
0.7	0	0	18	18	4	0	40	0.48
0.6	0	4	18	20	6	0	48	0.57
0.4	0	10	20	20	10	2	62	0.74
0.3	0	10	20	20	10	2	62	0.74
0.2	12	10	20	20	10	2	74	0.88
0.1	22	10	20	20	10	2	84	1
0.09	22	10	20	20	10	2	84	1
0.08	22	10	20	20	10	2	84	1
0.07	22	10	20	20	10	2	84	1
0.06	22	10	20	20	10	2	84	1
0.05	22	10	20	20	10	2	84	1
0.04	22	10	20	20	10	2	84	1
0.03	22	10	20	20	10	2	84	1
0.02	22	10	20	20	10	2	84	1
0.01	22	10	20	20	6	0	78	0.93
0.005	22	6	2	0	0	0	30	0.36


ТОЧНІСТЬ КЛАСИФІКАЦІЇ ( $\delta = 15\%$ )

spread (вплив)	Клас						$\Sigma$	К
	S0 (1)	S1 (2)	S2 (3)	S3 (4)	S4 (5)	S5 (6)		
Нзар. тест	22	10	20	20	10	2	84	-
1	0	0	18	16	0	0	34	0.40
0.9	0	0	18	18	2	0	38	0.45
0.8	0	0	20	20	4	0	44	0.52
0.7	0	4	20	20	8	0	52	0.62
0.6	0	10	20	20	10	2	62	0.74
0.5	0	10	20	20	10	2	62	0.74
0.4	0	10	20	20	10	2	62	0.72
0.3	0	10	20	20	10	2	62	0.72
0.2	12	10	20	20	10	2	74	0.88
0.1	22	10	20	20	10	2	84	1
0.09	22	10	20	20	10	2	84	1
0.08	22	10	20	20	10	2	84	1
0.07	22	10	20	20	10	2	84	1
0.06	22	10	20	20	10	2	84	1
0.05	22	10	20	20	10	2	84	1
0.04	22	10	20	20	10	2	84	1
0.03	22	10	20	20	10	2	84	1
0.02	22	10	20	20	10	2	84	1
0.01	22	10	20	20	10	2	84	1
0.005	22	10	20	20	10	2	84	1

## ТОЧНІСТЬ КЛАСИФІКАТОРА ВІД ПАРАМЕТРА ВПЛИВУ

При навчанні ІНМ задається параметр впливу *spread* (або його ще називають параметр згладжування), який пропорційний радіусам базисних функцій  $\sigma_j^2$ .

Ці радіуси характеризують перекриття радіально-базисних функцій та впливають на помилку навчання та ефективність класифікатора.



13

Результати класифікації при навчанні на  $N3 = 192$  векторах

Результати класифікації при навчанні на  $N4 = 130$  векторах

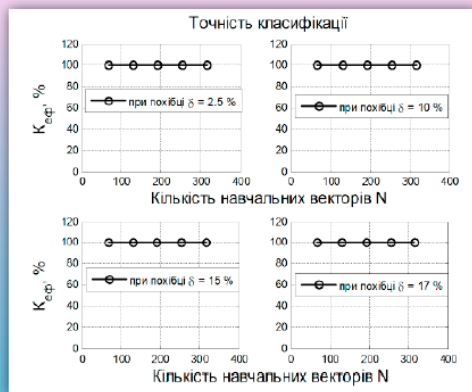
Помилка тестових векторів	Клас						$\Sigma$	Кеф	Помилка тестових векторів	Клас						$\Sigma$	Кеф
	S0 (1)	S1 (2)	S2 (3)	S3 (4)	S4 (5)	S5 (6)				S0 (1)	S1 (2)	S2 (3)	S3 (4)	S4 (5)	S5 (6)		
Нзаг. тест	22	10	20	20	10	2	84	1	Нзаг. тест	22	10	20	20	10	2	84	1
$\delta = 2,5\%$	22	10	20	20	10	2	84	1	$\delta = 2,5\%$	22	10	20	20	10	2	84	1
$\delta = 10\%$	22	10	20	20	10	2	84	1	$\delta = 10\%$	22	10	20	20	10	2	84	1
$\delta = 15\%$	22	10	20	20	10	2	84	1	$\delta = 15\%$	22	10	20	20	6	2	84	1
$\delta = 17\%$	22	10	20	20	10	2	84	1	$\delta = 17\%$	22	10	20	20	6	2	84	1
$\delta = 20\%$	22	10	20	20	10	2	84	1	$\delta = 20\%$	22	10	20	18	4	2	82	0,9762
$\delta = 25\%$	22	10	20	20	8	0	82	0,9524	$\delta = 25\%$	22	10	20	12	0	0	66	0,7857
$\delta = 30\%$	22	10	20	18	4	0	74	0,881	$\delta = 30\%$	22	10	12	2	0	0	48	0,5714
$\delta = 35\%$	22	10	12	2	0	0	46	0,5476	$\delta = 35\%$	22	8	2	0	0	0	34	0,4048

15

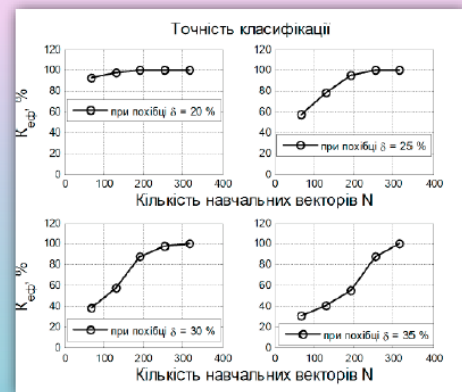
### Результати класифікації при навчанні на $N5 = 68$ векторах

Похибка тестових векторів	Клас						$\Sigma$	Кеф
	S0 (1)	S1 (2)	S2 (3)	S3 (4)	S4 (5)	S5 (6)		
Нзаг. тест	22	10	20	20	10	2	84	1
$\delta = 2,5\%$	22	10	20	20	10	2	84	1
$\delta = 10\%$	22	10	20	20	10	2	84	1
$\delta = 15\%$	22	10	20	20	10	2	84	1
$\delta = 17\%$	22	10	20	20	10	2	84	1
$\delta = 20\%$	22	10	20	20	6	0	78	0,9286
$\delta = 25\%$	22	10	14	2	0	0	48	0,5714
$\delta = 30\%$	22	8	2	0	0	0	32	0,381
$\delta = 35\%$	22	4	0	0	0	0	26	0,3095

16



Дієвість класифікатора від розмірності вхідних даних при  $\delta = 2,5\%, 10\%, 15\%, 17\%$  вхідних векторів діагностичних ознак



Дієвість класифікатора від розмірності вхідних даних при  $\delta = 20\%, 25\%, 30\%, 35\%$  вхідних векторів діагностичних ознак

17



## ВИСНОВКИ

- ▶ В магістерській атестаційній роботі проведено аналіз методів класифікації. Проаналізовано архітектури та типи нейронних мереж, які використовуються для класифікації, та обрано ймовірнісну мережу PNN як основу для класифікатора системи діагностики. Для побудови PNN-мережі було сформовано навчальні та тестові множини векторів, які повністю відповідають класам стану діагностичного об'єкту. Реалізовано ймовірнісну НМ в програмному забезпеченні Matlab → Simulink та представлено структуру її шарів.
- ▶ Сформований класифікатор протестовано на розпізнавання стану об'єкту за допомогою тестових множин. Результати показали вирішувальність мережею достовірної класифікації.
- ▶ Проведена оцінка ефективності класифікатора від параметру впливу *spread*. Встановлено, що для безпомилкового визначення стану об'єкта величина *spread* має належати інтервалу  $[0,02; 0,07]$ .
- ▶ Проведена оцінка ефективності класифікатора від кількості об'єктів навчальної множини. За результатами аналізу встановлено, що навчання нейронної мережі накладає обмеження правильної класифікації на порядок величини похибки елементів вхідної множини.
- ▶ Проаналізовано вплив навчальної множини на якість класифікатора технічного стану. Точність визначення стану об'єкту досягає високих результатів. Похибки елементів параметрів вхідних векторів у розмірі до 17 % від вектора діагностичних ознак А0 застосована НМ здатна розрізняти по класам при навчанні з різницею між елементами станів об'єкту всього в 0,5 %. За необхідністю покращити вірогідність класифікації, необхідно збільшувати навчальну множину.

## ДОДАТОК Б



## ГІБРИДНІ НЕЙРОННІ МЕРЕЖІ З ІМУННИМ НАВЧАННЯМ ДЛЯ РОЗВ'ЯЗАННЯ ЗАДАЧІ ПРОГНОЗУВАННЯ ЧАСОВИХ РЯДІВ

Гніденко В.А., Звонкова В.О.

Науковий керівник – д.т.н., проф. Корабльов М.М.  
Харківський національний університет радіоелектроніки  
(61166, Харків, пр. Науки, 14, каф. КІТС, тел. (057) 702-02-45)  
e-mail: volodymyr.hnidenko@nure.ua, тел. (095) 857-87-83  
vlada.zvonkova@nure.ua, тел. (068) 879-69-00

This paper explores the principles of neural network hybridization and immune algorithms, which allows us to create new types of information processing models that have a higher quality of problem solving while reducing computational training costs. The use of hybrid neural networks for solving time series prediction is considered

Розробка та впровадження штучних нейронних мереж (ШНМ) на базі прогресивних технологій є одним з пріоритетних напрямків розвитку галузей науки та техніки. Основні обмеження відомих методів і технологій, які використовуються на даний час, обумовлені недостатньою ефективністю розв'язання проблеми навчання ШНМ, налаштування і адаптації до проблемної області, обробки неповної та неточної вихідної інформації, інтерпретації даних і накопичення знань представлення інформації, яка поступає від різних джерел, тощо. Тому однією із провідних тенденцій є розвиток інтегрованих, гібридних систем на основі глибокого навчання.

Подібні системи складаються з різних елементів (компонентів), об'єднаних в інтересах досягнення поставлених цілей. Інтеграція і гібридизація різних методів і технологій дозволяє вирішувати складні задачі, які неможливо вирішити на основі окремих методів або технологій. Побудова гібридних нейронних мереж (ГНМ), які складаються з різних типів нейронних мереж (НМ), кожна з яких навчається за певним алгоритмом пошарово, в багатьох випадках дозволяє значно підвищити ефективність функціонування нейронних мереж.

В даній роботі досліджуються принципи гібридизації НМ та імунних алгоритмів, що дозволяє створювати нові типи моделей обробки інформації, які мають більш високу якість розв'язання задач та одночасного зниження обчислювальних витрат на навчання. Синтез ГНМ, які використовуються для розв'язання конкретної прикладної задачі на основі заданої навчальної вибірки, представляє собою достатньо складну проблему, яка полягає у попередньому визначенні початкової топології НМ для даного класу прикладних задач (наприклад, класифікації, апроксимації, прийняття рішень, прогнозування за навчальними вибірками тощо), подальшої модифікації НМ за навчальною вибіркою, яка відповідає даній прикладній задачі, та утворення гібридної структури за рахунок

створення модуля, до складу якого входить базова НМ, або ансамблю модулів, що дає нові можливості для підвищення ефективності розв'язання поставленої задачі.

Синтез ГНМ можна представити у вигляді поступового розв'язання наступних задач.

1. Задача вибору топології базової нейронної мережі, яка може бути розв'язана з використанням різних методів, зокрема методу перебору.

2. Модифікація базової нейронної мережі (БНМ) на основі розв'язання задачі багатокритеріальної оптимізації за рахунок зміни кількості нейронів у прихованих шарах, перехресних зв'язків, визначення значень вагових коефіцієнтів. Ця задача може бути розв'язана з використанням штучних імунних систем. Оптимальним є використання імунного алгоритму, який пристосовується до продуктивності пошуку на кожній ітерації та «адаптує» свої параметри клонування, мутації та редагування.

3. Структурно-параметричний синтез модуля БНМ.

4. Структурно-параметричний синтез ансамблю, що складається з модулів НМ.

Розглянуто застосування ГНМ для розв'язання задачі прогнозування часових рядів. У певних практичних випадках задачі прогнозування кількість вхідних змінних може бути достатньо великою і досягати тисяч чи навіть десятків тисяч змінних. Зазвичай це задачі, в яких окрім основного часового ряду, що прогнозується, присутні зовнішні часові ряди, що потенційно впливають на основний. Більшість існуючих постановок задачі прогнозування припускають, що характер прогнозованого процесу на спостережуваному періоді не змінюється, і, таким чином, задачу можна вирішити шляхом знаходження потрібної моделі і оцінки її параметрів, використовуючи всі наявні дані. Однак найчастіше поведінка прогнозованого процесу може кілька разів суттєво змінюватися протягом спостережуваного періоду, що робить таку постановку задачі некоректною – одна єдина модель не зможе описати кілька різних станів процесу.

Для покращення якості прогнозу можна використовувати комплексуювання оцінок, отриманих за допомогою різних моделей. Під комплексуюванням розуміється зважена сума оцінок, отриманих за допомогою генерованого набору моделей. Вагові коефіцієнти визначаються за допомогою зовнішнього критерію оптимальності моделей – дисперсії на експериментальній вибірці. Множина моделей виходить перебором варіантів розбиття вихідної вибірки на підвибірки і перебором різних методів прогнозування.

