



## ІНТЕГРАЦІЯ ШТУЧНИХ НЕЙРОННИХ МЕРЕЖ ДЛЯ ІДЕНТИФІКАЦІЇ СТАНІВ КОМП'ЮТЕРНИХ СИСТЕМ

Оксана Поморова

Кафедра системного програмування Хмельницького національного університету,  
Україна, Хмельницький, вул. Інститутська, 11,  
kism@beta.tup.km.ua, pomorova@ieee.org

**Резюме:** У статті представлено основи методології інтелектуалізації процесу діагностування комп'ютерних систем. Запропоновані інформаційна модель, метод та засоби кластеризації станів комп'ютерних систем забезпечують можливість діагностування на основі неповної діагностичної інформації. Для ідентифікації станів комп'ютерних систем використано спілку нейромережних експертів, котрі побудовані з використанням штучних нейронних мереж архітектур ART2 та SOM.

**Ключові слова:** Діагностування комп'ютерних систем, штучні нейронні мережі, спілка нейромережних експертів, кластеризація станів комп'ютерних систем.

### 1. ВСТУП

Основними задачами діагностування комп'ютерних систем (КС) на етапі експлуатації є визначення роботоздатності КС, ідентифікація та прогнозування їх стану.

Сучасні комп'ютерні системи мають особливості, котрі ускладнюють процес діагностування та зменшують його ефективність:

1) низький рівень контролепридатності КС та їх складових;

2) відсутність або відносно висока вартість діагностичних програм та апаратних засобів діагностування КС;

3) постійне зростання спектру апаратних складових та їх модернізація роблять нерентабельною закупівлю вузькоспеціалізованого діагностичного обладнання;

4) етап експлуатації КС недостатньо забезпечений документацією і в той же час на цьому етапі необхідно забезпечити діагностування широкого спектру КС та їх складових, тому успішність етапу експлуатації залежить від рівня кваліфікації спеціалістів, що експлуатують та обслуговують комп'ютерну техніку.

До систем діагностування, котрі функціонують на етапі експлуатації КС, пред'являється ряд вимог:

– гнучкість, для налагодження на широкий

спектр номенклатури складових КС;

– висока достовірність результатів діагностування, що забезпечить можливість зниження вимог до кваліфікації обслуговуючого персоналу;

– можливість самонавчання систем діагностування для виявлення невідомих раніше несправностей;

– модульний принцип побудови для забезпечення подальшого нарощення можливостей засобів діагностування.

На сьогодні апаратні засоби діагностування КС на етапі експлуатації практично відсутні, тому домінуючу роль відіграють програмні засоби (Motherboard Monitor, Performance Test, Dr.Hardware, SiSoftware Sandra, SMART-и жорстких дисків та ін.) [1], які надаються виробниками апаратних складових КС, розробниками операційних систем та незалежними фірмами. Вказані засоби фіксують параметри окремих компонентів КС та повідомляють користувача про їх відхилення. Користувач повинен самостійно провести оцінку технічного стану КС, критичності виявлених відхилень параметрів та характеристик і їх наслідків. Необхідні заходи щодо усунення проблем користувач визначає на свій розсуд, тому правильність та оптимальність цих заходів залежать від його кваліфікації.

Перспективним напрямком вдосконалення засобів технічного діагностування є

використання ними компонентів штучного інтелекту: продукційних правил, нечіткої логіки, штучних нейронних мереж (ШНМ) [2-4].

Зокрема, основними перевагами ШНМ є можливості отримання з їх допомогою інформації у випадках, коли дослідник не може вказати функційних залежностей між параметрами, що характеризують об'єкт діагностування (ОД), опрацювання значень вхідних векторів, яких не було у навчальних вибірках, прискорення обчислень за рахунок їх розпаралелювання [5].

ШНМ у галузі технічного діагностування використовуються для ідентифікації несправностей та реалізуються у вигляді окремих компонентів засобів діагностування [6, 7]. Вхідною інформацією для ШНМ є знання про структуру та поведінку об'єктів діагностування, при цьому провідну роль відіграють саме поведінкові аспекти структурних чи функційних компонентів ОД. Сучасні засоби технічного діагностування, що використовують інтелектуальні компоненти, орієнтовані на вирішення окремих вузькоспеціалізованих діагностичних задач та не забезпечують достатнього рівня універсальності.

Враховуючи вищезазначені особливості КС та вимоги до засобів їх діагностування на етапі експлуатації, питання розроблення і вдосконалення таких засобів є актуальними та потребують подальших досліджень.

Метою дослідження є розроблення нових підходів до діагностування КС на етапі експлуатації, в умовах неповної діагностичної інформації щодо значень параметрів і характеристик апаратних та програмних складових.

Для досягнення мети необхідно розробити методологію інтелектуалізації процесу діагностування КС за рахунок використання ШНМ та, при потребі, інших компонентів штучного інтелекту.

У процесі діагностування КС необхідно забезпечити контроль технічного стану, пошук місця та визначення причин несправності та прогнозування технічного стану. Для вирішення цих задач необхідно дослідити можливість використання ШНМ для кластеризації та ідентифікації станів КС в умовах неповної інформації і розробити відповідні засоби на їх основі.

## 2. ІНФОРМАЦІЙНА МОДЕЛЬ КС

При розробленні засобів діагностування високий рівень складності сучасних КС обмежує використання методів моделювання, що

базуються тільки на послідовній декомпозиції КС на компоненти. При об'єднанні апаратних та програмних компонентів у комп'ютерну систему виникає ряд якісно нових властивостей, які не можуть бути виявлені шляхом аналізу властивостей окремих компонентів таких систем.

Одним із варіантів вирішення цієї проблеми є побудова інформаційних моделей на основі даних експериментів та спостережень за реальними КС. При цьому структура КС практично не відображається у інформаційних моделях, але при цьому суттєву роль починають відігравати засоби моніторингу та знання експертів-діагностів, які є основними джерелами інформації про параметри та характеристики КС [8].

Результати моніторингу, знання експертів діагностів та інші відомості, що стосуються КС та процесу їх діагностування зберігаються у базах знань (БЗ) засобів діагностування.

Запропонована в [9] інформаційна модель КС є універсальною і дозволяє на початкових етапах звести задачу діагностування до задач кластеризації та ідентифікації станів КС.

Інформаційною моделлю КС назвемо трійку:

$$M_{\text{инф.}} = \{x(\omega_h), R(\omega_h), |z_j(\omega_h)|_{j=1}^n\}_{h=1}^m \quad (1)$$

де:  $\omega_h \in \Omega$  - деякий стан КС з множини усіх можливих станів  $\Omega$ ,  $x(\omega_h)$  - вектор інформаційного опису стану КС,  $R(\omega_h)$  - характеристична функція класу, до якого належить стан КС,  $z(\omega_h)$  - деталізуючі характеристики стану, котрий описується вектором  $x(\omega_h)$ ,  $h$  - кількість описаних станів,  $j$  - кількість деталізуючих характеристик для кожного стану.

У випадку відсутності експертної інформації про параметри та характеристики КС та її компонентів деталізуючі характеристики можуть бути відсутні.

Значення елементів векторів інформаційного опису збираються з різних джерел:

- результатів моніторингу КС на етапі експлуатації з використанням відомих чи спеціально розроблених засобів моніторингу;
- результатів тестування КС фірмами - виробниками;
- результатів тестування КС користувачем у різних режимах роботи при різних навантаженнях;
- даних, одержаних на основі внесення змін у інформаційні вектори, що характеризують ідеальний стан КС;

– експертних даних, на основі яких формуються описи несправних станів КС.

Повнота інформаційного опису залежить від кількості елементів вектора  $x(\omega)$  та їх інформативності.

Для проведення ідентифікації стану КС необхідно визначити  $R(\omega)$ , тобто віднести стан КС до відповідного класу.

Для цього випадковим чином обираються  $K$  ядер класів  $\{c_k\} = c(\omega_1), \dots, c(\omega_k)$ ,  $k = 1, \dots, K$ , які визначаються як типові для свого класу стани (інформаційні описи)  $c(\omega) = |c_i(\omega)|_{i=1}^n$  у просторі усіх можливих станів.

Введемо міру близькості  $d(x(\omega_i), c(\omega_i))$ , яка тим менша, чим більше поточний інформаційний опис КС схожий на ядро класу (типовий інформаційний опис). У якості міри близькості використаємо евклідову міру [10]:

$$d(x, c) = \left( \sum_{i=1}^n (x_i - c_i)^2 \right)^{1/2}. \quad (2)$$

При незмінному розбитті побудуємо функцію  $R(\omega)$  таким чином, щоб мінімізувати сумарну міру близькості для всієї множини  $x(\omega_h)$ :

$$\min \{ D = \sum_h \left( \sum_i (x_i(\omega_h) - c_i(R(\omega_h)))^2 \right)^{1/2} \}, \quad (3)$$

де:  $h = 1, \dots, m$ ,  $i = 1, \dots, n$

Задача пошуку мінімуму  $D$  еквівалентна пошуку максимуму виразу:

$$\min D = \max \sum_h \sum_i x_i(\omega_h) c_i(R(\omega_h)). \quad (4)$$

Одержавши функцію  $R(\omega)$ , отримуємо можливість кожному інформаційному опису  $x(\omega) = |x_i(\omega)|_{i=1}^n$  поставити у відповідність стан КС із усієї множини станів.

Відслідковування та аналіз динаміки зміни станів КС на протязі деякого періоду часу  $T$  є основою для прогнозування станів КС.

### 3. НЕЙРОМЕРЕЖНІ ЕКСПЕРТИ

Для кластеризації станів КС на основі запропонованої інформаційної моделі (1-4) використаємо штучні нейронні мережі (ШНМ).

У процесі діагностування не вся множина станів КС є відомою - існує підмножина несправностей, які раніше не зустрічались і не описані у базах знань систем діагностування

експертами-діагностами. Наявність та кількість таких несправностей неможливо вказати заздалегідь.

Але оцінка значення міри близькості (2) таких станів до відомих дає змогу висунути гіпотези стосовно їх ідентифікації, тому для досягнення мети дослідження необхідно обрати штучні нейронні мережі таких архітектур, що, з однієї сторони, відобразять групи близьких станів у групи близьких кластерів та, з іншої сторони, забезпечать відображення інформаційних описів невідомих раніше несправних станів у нові кластери.

Особливістю КС є те, що набори їх компонентів можуть бути достатньо різноманітними, тому результати кластеризації станів одних моделей КС не можуть використовуватись для кластеризації станів інших моделей. За цієї причини використання для кластеризації станів КС нейромереж, що передбачають навчання з учителем, є неефективним.

Поширеними та дослідженими архітектурами, що задовольняють вказаним вимогам є карти Кохонена, що самоорганізуються, та мережі адаптивного резонансу (ART) [11].

Карта Кохонена (SOM) зберігає топологію вхідного простору (близьким кластерам вхідних векторів відповідають близько розміщені нейрони) та відображає щільність вхідних сигналів шляхом більшого їх розрішення на карті кластерів [12].

Навчання SOM здійснюється за принципом:

$${}_i w(q) = (1 - \alpha) \cdot {}_i w(q-1) + \alpha p(q), \quad (5)$$

де:  $p(q)$  - вхідний вектор інформаційного опису  $x(\omega)$ ,  $q$  - номер кроку самонавчання,  $w(q)$  - матриця вагових коефіцієнтів,  $i$  - номер тієї стрічки матриці ваг, яка коригується,  $\alpha$  - параметр швидкості навчання.

Перед навчанням необхідно задати топологію карти та вказати її розмірність.

Після навчання SOM здатна кластеризувати типові стани КС.

Також існує можливість відображення на карті траєкторії зміщення станів КС на протязі деякого періоду часу, що дає змогу здійснити прогнозування станів та виявити граничні стани (КС справна, але наявність систематичних відхилень параметрів може призвести у майбутньому до виходу з ладу її компонентів).

Але, поява нетипових станів (невдомих раніше несправностей - їх параметри та характеристики яких суттєво відрізняються від тих, що були у навчальних вибірках), призводить

до їх невірної кластеризації, тому, що для них не було сформовано кластерів на карті. Зазвичай вони розміщені у кластерах, що знаходяться у кутах або по краях карти, хоча не є до них топологічно близькими, та однозначно не вирізняються.

Усунемо вказаний недолік, використавши для кластеризації станів КС штучну нейронну мережу адаптивного резонансу (ART).

Використання мережі адаптивного резонансу не вимагає апріорних знань про кількість класів [13]. ART реалізує алгоритм кластеризації, котрий схожий на алгоритм "послідовного лідера", відповідно до якого перший вхідний вектор вважається зразком першого кластера, а наступний порівнюється зі зразком першого кластера.

Вхідний вектор буде належати до першого кластера, якщо відстань між ним та зразком першого кластера буде меншою порога, вказаного розробником. Інакше для другого вхідного вектора буде створено окремий кластер. Цей процес повторюється для всіх наступних вхідних векторів.

Число кластерів росте з часом і залежить як від значення порога, так і від метрики відстані, що використовується для порівняння вхідних векторів і зразків класів. Обмеження на кількість нейронів у вихідному шарі визначаються лише можливостями обчислювальних засобів та розробниками. Для опрацювання вхідних векторів, значеннями яких є дійсні числа, використаємо архітектуру ART2 [14].

Отже, мережа ART має можливість нарощення кількості кластерів при виявленні нових несправностей, але не надає інформації про близькість станів та їх зміщення у часі.

Кластеризацію та прогнозування станів КС здійснимо на основі опрацювання результатів паралельного функціонування обох нейромереж - ART2 і SOM. Вказані ШНМ назовемо *нейромережними експертами* стану КС.

#### 4. НАВЧАННЯ НЕЙРОМЕРЕЖНИХ ЕКСПЕРТІВ

Вхідною інформацією для кластеризації станів КС нейромережними експертами є вектори інформаційного опису  $x(\omega)$ , які складаються з  $n$  елементів:

$$x(\omega) = \{x^1(\omega), x^2(\omega), \dots, x^n(\omega)\}.$$

На виході нейромережні експерти вкажуть номери класів, до яких належать стани КС та траєкторію зміщення станів на протязі заданого періоду часу.

Кількість елементів вектора інформаційного опису для різних КС буде різною. Вона залежить від об'ємів наявної діагностичної інформації та можливостей засобів збирання значень параметрів та характеристик КС.

Для проведення експериментальних досліджень використаємо КС, що функціонує на базі процесора Intel Celeron 1.7 GHz, 256 Кб ОЗП, материнська плата MSI 845PE Max, жорсткий диск Samsung (100 Гб). Діагностична інформація одержана з використанням програмних засобів моніторингу КС та експертних знань.

Сформуємо вектор інформаційного опису стану КС, який містить 24 елементи.

Параметри процесора:

$x^1(\omega)$  - частота ядра процесора,

$x^2(\omega)$  - температура процесора,

$x^3(\omega)$  - термостійкість системи охолодження процесора,

$x^4(\omega)$  - потужність ядра процесора,

$x^5(\omega)$  - швидкість вентилятора процесора,

$x^6(\omega)$  - напруга процесора,

$x^7(\omega)$  - завантаження процесора (%).

Вольтаж компонентів системної плати:

$x^8(\omega)$  - вольтаж - 5 V,

$x^9(\omega)$  - вольтаж +5 V,

$x^{10}(\omega)$  - вольтаж +3.3 V,

$x^{11}(\omega)$  - вольтаж +12 V,

$x^{12}(\omega)$  - вольтаж - 12 V.

Характеристики КС:

$x^{13}(\omega)$  - температура блоку живлення,

$x^{14}(\omega)$  - температура системної плати,

$x^{15}(\omega)$  - розмір оперативної пам'яті,

$x^{16}(\omega)$  - розмір swar.

Характеристики жорсткого диску (ЖД):

$x^{17}(\omega)$  - кількість дефектних секторів на ЖД,

$x^{18}(\omega)$  - кількість старт / стопних циклів ЖД,

$x^{19}(\omega)$  - кількість обертів шпиндельного двигуна,

$x^{20}(\omega)$  - кількість позиціонувань головок зчитування / запису,

$x^{21}(\omega)$  - частота виникнення помилок при зчитуванні даних,

$x^{22}(\omega)$  - середня пропускна здатність ЖД,

$x^{23}(\omega)$  - частота "програмних" помилок при зчитуванні даних,

$x^{24}(\omega)$  - температура жорсткого диску.

До складу навчальної вибірки увійшло 250 векторів інформаційного опису, що характеризують 50 станів КС, тестова вибірка містить 30 векторів, серед яких 5 описують нові несправні стани.

Реалізація нейромережних експертів здійснювалась в системі Matlab.

*SOM.* Розмірність SOM залежить від кількості станів, описаних у навчальній вибірці, необхідно також залишити запасні класи для викидів у них невідомих станів КС.

При моделюванні карти Кохонена кількість класів  $K$ , що можуть відобразитись, повинна перевищувати кількість відомих станів КС. Вона була обрана рівною 80, тому будувалась двовірна гексагональна карта розміру  $8 \times 10$ .

Вид карти, одержаної після навчання мережі, та траєкторію зміни станів тестової вибірки на протязі періоду часу від  $t = 0$  до  $t = k$ , де  $k=24$ , зображено на рис.1.

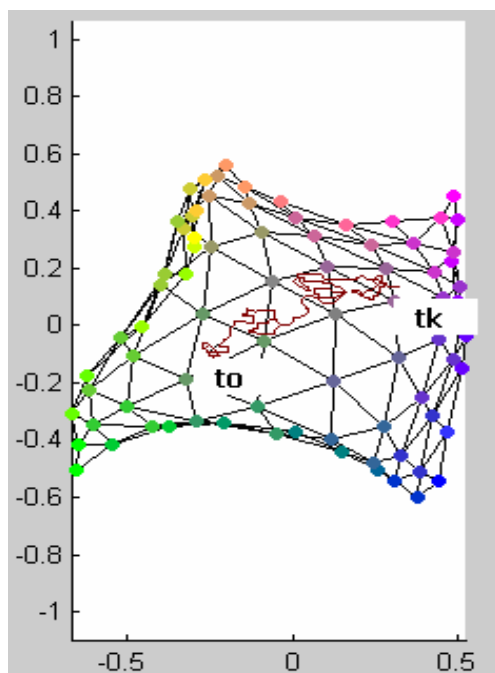


Рис.1 - Карта Кохонена, одержана після навчання та тестування.

Різні відтінки кольору вузлів карти обмежують різні кластери, що характеризують різні стани КС.

Вид матриці відстаней між одержаними кластерами та проекції відстаней для перших трьох вимірів ( $x_1 - x_3$ ) наведено на рис. 2. Різні кольори відображають різні відстані, шкала масштабування наведена поряд із вимірами.

Результати кластеризації векторів інформаційних описів станів КС навчальної та тестової вибірки (рис.3 (а-г)) наведені у таблиці 1.

Кластеризація здійснювалась після 1000, 2000, 3000 і 5000 ітерацій навчання.

Аналіз діаграм та результатів розподілу станів за кластерами показує, що у даному випадку для навчання карти Кохонена достатньо 3000 ітерацій. Подальше навчання результатів суттєво не покращує. Розпізнавання станів КС з тестової вибірки не дало змоги ідентифікувати невідомі мережі стани.

Прогнозування станів КС здійснюється експертом – діагностом на основі оцінки траєкторії зміщення станів у часі.

*ART2.* Результати моделювання мережі ART2 наведені у таблиці 2. Суттєвий вплив на результати має значення параметру контролю, який відображає бажану ступінь "подібності" вхідних векторів. Оптимальну кластеризацію станів КС було отримано при значеннях параметру контролю, що лежать у інтервалі  $[0,7 - 0,8]$ . Вибір значень параметру контролю менших 0,7 призводить до зменшення кількості класів, що знижує якість кластеризації станів КС. Вибір значень більших 0,8 призводить до дроблення класів, що знижує узагальнюючі властивості мережі.

Мережа ART2 сформувала додаткові кластери для невідомих їй раніше станів, що дало змогу чітко вирізнити нові несправні стани КС.

Інформації про ці несправності не було у навчальній вибірці. Виявлення нових станів не вимагало розроблення спеціальних методів.

Процес навчання нейромережних експертів займає проміжки часу 15-50 хв, за ресурсами часу він є доступним для середньостатистичної КС.

Проведені експерименти свідчать про те, що результати кластеризації станів КС за допомогою окремого використання нейромереж SOM або ART2 можна покращити за рахунок здійснення паралельної кластеризації станів обома нейромережними експертами та взаємодоповнення одержаних результатів.







Рис.2 – Матриця відстаней між кластерами та проєкції відстаней




(а) – після 1000 ітерацій навчання



(б) – після 2000 ітерацій навчання



(в) – після 3000 ітерацій навчання



(г) – після 5000 ітерацій навчання

Рис. 3 - Результати кластеризації станів навчальної вибірки,  
X – кількість кластерів; Y – кількість станів у кластерах.

Таблиця 1. Результати функціонування SOM

Кількість кроків навчання	Навчальна вибірка			Тестова вибірка		
	Кількість станів КС у вибірці	Кількість заповнених кластерів	% вірно класифікованих станів	Кількість станів КС у вибірці	Кількість нових станів КС у вибірці	% вірно класифікованих станів
1000	50	56	49	20	5	25
2000	50	56	74	20	5	40
3000	50	56	87	20	5	60
5000	50	56	89	20	5	60

Таблиця 2. Результати навчання та функціонування ART2

Значення параметра контролю	Навчальна вибірка			Тестова вибірка			
	Кількість станів КС у вибірці	Кількість сформованих кластерів	% вірно класифікованих станів	Кількість станів КС у вибірці	Кількість нових станів у вибірці	Кількість нових кластерів	% вірно класифікованих станів
0,4	50	12	18	20	5	1	15
0,5	50	24	35	20	5	0	30
0,6	50	40	46	20	5	0	35
0,7	50	49	80	20	5	4	85
0,8	50	52	82	20	5	5	90
0,9	50	119	23	20	5	9	10

### 5. Інтегрована ідентифікація станів КС

Для ідентифікації стану КС з використанням нейромережних експертів архітектур SOM та ART2, сформуємо інтегровану конструкцію (рис.4) та назвемо її *спілкою нейромережних експертів ідентифікації стану КС*.




Рис. 4 - Структурна схема спілки нейромережних експертів.

Перед початком процесу діагностування на протязі деякого періоду часу комп'ютерна система вважається справною. За допомогою засобів моніторингу збираються значення її параметрів та характеристик, вони доповнюються експертними знаннями та на основі цієї інформації формується набір векторів інформаційного опису КС для навчання спілки нейромережних експертів. До складу навчальної вибірки обов'язково входить діагностична інформація про відомі несправні стани КС.

Після навчання нейромережні експерти працюють у режимі моніторингу стану КС. Проводиться формування векторів інформаційного опису поточних станів КС, відображення на карті Кохонена траєкторії станів у часі та видається список нових кластерів, сформованих мережею ART.

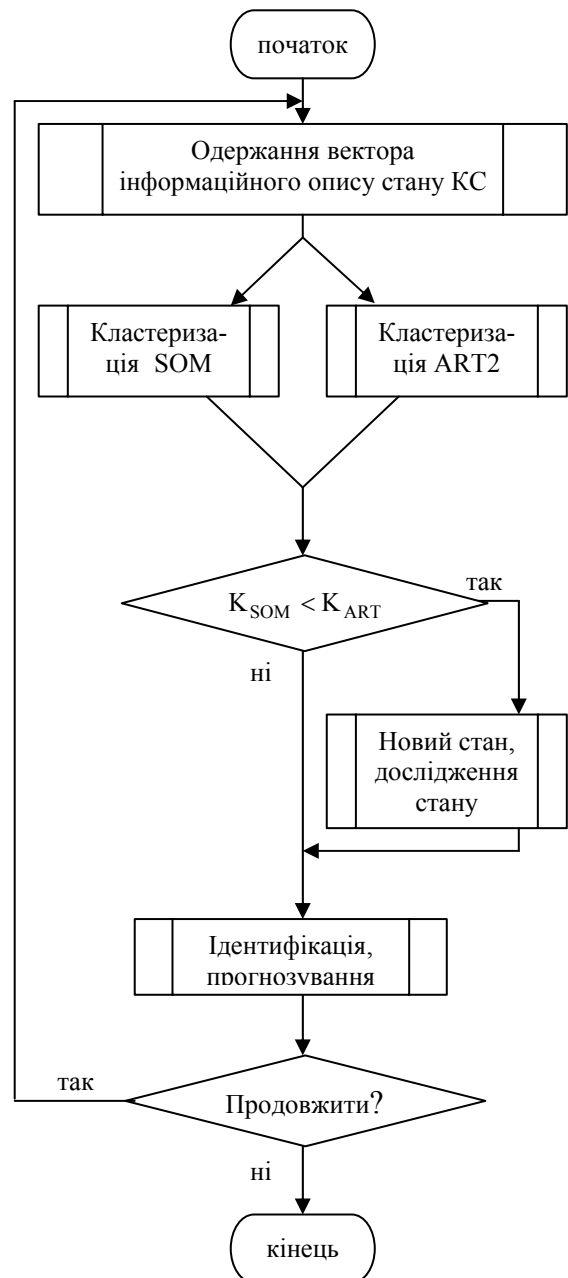


Рис.5 – Інтегрована ідентифікація станів КС

У разі виявлення зміщення поточного стану КС та виходу його за межі кластеру справних

станів чи формування нового кластеру мережею ART проводиться ідентифікація стану КС на основі результатів роботи обох нейромережних експертів.

Укрупнену блок-схему алгоритму інтегрованої ідентифікації станів КС наведено на рис.5.

Узгодження результатів паралельного функціонування нейромережних експертів здійснюється за допомогою процедури узгодження рішень, котра базується на продукційному опрацюванні додаткової інформації про несправні стани (з баз знань засобів діагностування та від експертів-діагностів) дає змогу більш точно ідентифікувати стани КС.

Процес інтегрованої ідентифікації станів КС здійснюється під керуванням експерта – діагноста, який при виявленні невідомих раніше несправностей заносить інформацію про них у бази знань засобів діагностування КС та при потребі (накопиченні об'ємів інформації про невідомі раніше несправності) перенавчає спілку нейромережних експертів.

## 6. ВИСНОВКИ

1. Використання інформаційних моделей у засобах діагностування КС дає змогу за рахунок врахування результатів роботи програм моніторингу та знань експертів-діагностів описати стани КС в умовах неповної діагностичної інформації щодо значень параметрів і характеристик апаратних та програмних складових.

2. Штучні нейронні мережі архітектур ART2 і SOM забезпечують можливість кластеризації станів КС. Дослідження показали, що результати кластеризації станів КС цими мережами є взаємодоповнюючими.

3. Запропоновано новий підхід до ідентифікації станів КС з використанням спілки нейромережних експертів, який за рахунок узгодження результатів роботи нейромережних експертів забезпечує можливості кластеризації, прогнозування та виявлення невідомих раніше станів КС.

4. Допускається вплив на результати досліджень розміру та складу вектору інформаційного опису, тому питання вибору оптимальних кількості, складу та оцінки інформативності елементів вектора інформаційного опису потребують подальших досліджень.

## 7. ЛІТЕРАТУРА

- [1] Мюллер С. *Модернизация и ремонт ПК*, 16-е издание: Пер. с англ. - М.: Издательский дом «Вильямс», 2006. – 1328 с.
- [2] Локазюк В. М., Поморова О. В., Домінов А.О. *Інтелектуальне діагностування мікропроцесорних пристроїв та систем*: Навч. посібник для вузів. – Хмельницький – Київ: “Такі справи”, 2001. – 286с.
- [3] Rowland J. G., Jain L.C. Knowledge based systems for instrumentation diagnosis, system configuration and circuit and system design // *Eng. Application Artificial Intelligent.* – 1993. - vol. 6, no. 5, pp. 437-446.
- [4] Isermann R. On fuzzy logic applications for automatic control, supervision, and fault diagnosis // *IEEE Syst., Man, Cybern.* – 1998.- vol. 28, pp. 221-235.
- [5] Хайкин С. *Нейронные сети: полный курс*, 2-е издание. – М.: Издательский дом "Вильямс", 2006. -1104 с.
- [6] Totton K., Limb P.R. Experience in using neural networks for electronic diagnosis // *Proc. 2nd Int. Conf. Artif. Neural Networks.*- 1991., pp. 115-118.
- [7] AL-Jumah A.A., Arslan T., Artificial neural network based multiple fault diagnosis in digital circuits // *Proc. ICCAS*, - 1998. - vol. 2, pp. 304-307.
- [8] Cunningham P. A case study on the use of model-based systems for electronic fault diagnosis // *Artificial Intelligent Engineer.* - 1998. - vol. 12, pp. 283-295.
- [9] Pomorova O.V. Computer Devices Diagnostic Method on the Base of the Information Model, *Proc. of the International Conference TCSET'2006 "Modern problems of radio engineering, telecommunications and computer science"*, Lviv, Slavske, Ukraine, February 28-March 4 - 2006., с. 152-154.
- [10] Гайдышев И. Анализ и обработка данных: специальный справочник – СПб: Питер, 2001. – 752 с.
- [11] S.G. Tzafestas and P.J. Dalianis, "Fault diagnosis in complex systems using artificial neural networks," in *Proc. IEEE 3rd Conf. Contr. Applicat*, 1994, pp. 877-882.
- [12] Lampinen J., Kostianen T. Self-organizing map in data analysis - notes on overfitting and overinterpretation / *Proc. European Symposium on Artificial Neural Networks (ESANN'2000)*, Bruges, Belgium, 2000. - pp.239-244.
- [13] G.A.Carpenter, S. Grossberg “*Adaptive resonance theory*”, *The Handbook of Brain Theory and Neural Networks*, Second Edition, MIT Press, (2002).



[14] G. Carpenter, S. Grossberg, and D. Rosen, "ART 2-A: An adaptive resonance algorithm for rapid category learning and recognition," *Neural Networks*, vol. 4, pp. 493–504, 1991.



**Оксана Поморова**, у 1992 році закінчила факультет кібернетики Київського Національного Університету ім.Т.Шевченко.

Працювала інженером-програмістом та асистентом на кафедрі комп'ютерних систем та мереж Хмельницького

національного університету. У 2002 році

отримала науковий ступінь кандидата технічних наук. Працює доцентом на кафедрі системного програмування Хмельницького національного університету.

Область наукових інтересів: системи штучного інтелекту, діагностування мікропроцесорних пристроїв і систем, штучні нейронні мережі, експертні системи.

Опублікувала більше 40 наукових праць. Член інституту електрорадіоінженерів (IEEE).

# INTEGRATION OF ARTIFICIAL NEURAL NETWORKS FOR IDENTIFICATION OF COMPUTER SYSTEMS STATES

Oksana Pomorova

Department of System Programming Khmelnytsky National University,  
11 Institutyskya str., Khmelnytsky, 29016, Ukraine,  
pomorova@iee.org, kism@beta.tup.km.ua

**Abstract:** *The main principles of methodology of intellectualization computer systems diagnosing process are presented in paper. Offered the information model, method and means of computer systems states clusterization provide an opportunity of diagnosing on the basis of the incomplete diagnostic information. For identification of computer systems states are used the union of neural nets experts which are constructed with use of artificial neural networks architecture ART2 and SOM.*

**Keywords:** *Diagnosing of computer systems, Artificial neural networks, The union neural nets experts, Clusterization of computer systems states.*

## 1. INTRODUCTION

The primary goals of computer systems (CS) diagnosing at an operation stage are definitions of CS operability and forecasting of their states.

For today a hardware for diagnosing of computer systems at an operation stage practically are absent, therefore a dominating role for diagnosing play software which fix parameters of separate CS components and inform the user about their deviation. User defines necessary actions on elimination of problems; therefore correctness and an optimality of these actions depend from its qualification.

The perspective direction of improvement of technical diagnosing means is using of artificial neural networks (ANN) by them.

## 2. STATEMENT OF PROBLEM

The purpose of research are development and improvement of CS diagnosing means at an operation stage in conditions of the incomplete diagnostic information concerning values of hardware and software parameters and characteristics.

For achievement of the purpose is necessary to develop the methodology of intellectualization of CS diagnosing process at an operation stage, and also is necessary to investigate an opportunity of using of artificial neural networks for the decision of CS states clusterization and identifications problems and to develop corresponding means for their basis.

## 3. CS INFORMATION MODEL

By development of diagnosing means the high level of complexity of modern computer systems

limits using of modeling methods which are based only on consecutive decomposition of computer systems on components.

One of variants of this problem decision is construction of information models on the basis of the experimental data and supervision over real computer systems. Offered in [1] CS information model is universal and allows reducing a diagnosing problem at the initial stages to a problem of CS states clusterization.

## 4. NEURAL NETS EXPERTS

Artificial neural networks are used for realization of CS states clusterization means on the basis of the offered information model.

The problem consists in a choice such neural networks architecture which will display groups of nearby states in groups of nearby clusters and will provide adequate reflection of information descriptions unknown faults in state clusters.

The widespread and investigated architecture meeting specified requirements, are Kohonen self-organizing maps (SOM) and networks of an adaptive resonance (ART). Architecture ART2 using for processing input vectors which values are real numbers. We shall carry out clusterization and forecasting of CS states on the basis of results of neural nets ART2 and SOM. Specified neural nets we shall name neural nets experts of CS states.

## 5. TRAINING OF NEURAL NETS EXPERTS

The input information for CS states clusterization by neural nets experts are vectors of the information description which consist of  $n$  elements [1].

On output neural nets experts will specify numbers of classes to which CS states belong and a trajectory of states.

Value of elements of information description vectors the gather from different sources, namely:

- results of CS monitoring at an operation stage with use of the known or specially developed monitoring means;
- results of CS testing by firms - manufacturers;
- results of CS testing by the user at different operating modes at different loadings;
- data received on the basis of modification in information vectors which characterize an ideal CS state;
- expert data on the basis of which are formed the

descriptions of CS faults.

Completeness of the information description depends on quantity of elements of a vector and them comprehension.

Educational sample included 250 vectors of the information description which characterize 50 CS states; test sample contains 30 vectors among which 5 describe new faults.

*SOM.* At modeling SOM the quantity of classes has been selected equal 56, therefore was construction two-dimensional [7,8] hexagonal map. Results of CS information descriptions vectors clustering for educational and test samples are in table 1.

**Table 1. Results of functioning SOM**

Number training epochs	Training samples			Testing samples		
	Number of CS state	Number of fill clusters	% right state	Number of CS state	Number of new CS state	% right state
1000	50	56	49	20	5	25
2000	50	56	74	20	5	40
3000	50	56	87	20	5	60
5000	50	56	89	20	5	60

**Table 2. Results of training and functioning ART2**

Vigilance	Training samples			Testing samples			
	Number of CS state	Number of fill clusters	% right state	Number of CS state	Number of new CS state	Number of new clusters	% right state
0,4	50	12	18	20	5	1	15
0,5	50	24	35	20	5	0	30
0,6	50	40	46	20	5	0	35
0,7	50	49	80	20	5	4	85
0,8	50	52	82	20	5	5	90
0,9	50	119	23	20	5	9	10

Clustering was carried out after 1000, 2000, 3000 and 5000 iterations of training. The analysis of diagrams and results of states distribution shows, that in this case for training SOM there are enough 3000 iterations. The further training essentially does not improve results of functioning. Recognition by SOM of CS states from test sample has not given an opportunity to identify unknown states (faults).

ART2. Results of ART2 modeling are in tables 2. Parameter "vigilance" is essential influence on results. It displays a desirable degree of "similarity" of input vectors. Optimum clustering of CS states has been received at values of vigilance lay in an interval [0,7-0,8]. The choice of vigilance smaller 0,7 leads to reduction of quantity of classes that

reduces quality clustering of states. The choice of vigilance greater 0,8 leads to crushing of classes, that reduces generalizing properties of a network.

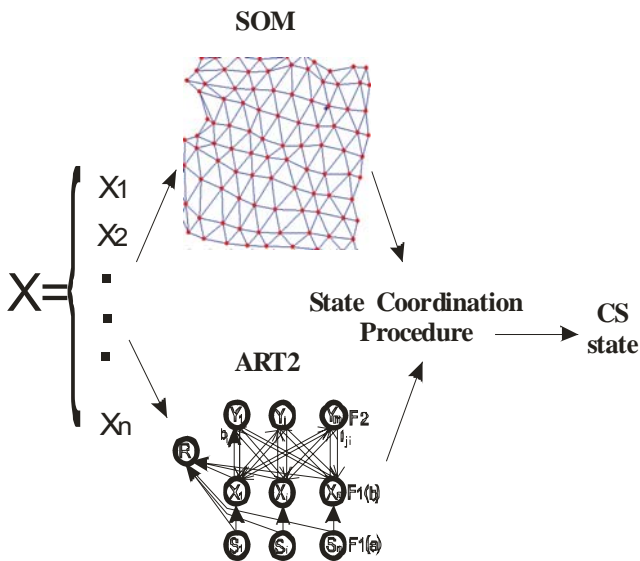
Network ART2 has enabled to reveal new states of computer system (faults) for which have been generated separate clusters. Information about these faults was not in educational sample. Revealing of new states did not demand development of special methods.

The lead experiments testify that results of CS states clustering by means of separate using of neural nets SOM and ART2 can be improved due to realization parallel clustering states both neural nets experts and integration of the received results.

## 6. INTEGRATED IDENTIFICATION OF CS STATES

The further coordination of parallel functioning neural nets experts results and using of the additional information on inoperative states (from knowledge bases of diagnosing means and from experts-diagnosticians) enables to identify CS states.

For identification of CS states with use neural nets experts SOM and ART2 we shall generate the integrated structure (fig.1) and we shall name it's the union of neural nets experts for identification of CS states.



**Fig. 1 - The block diagram of the union neural nets experts**

Process of the integrated identification of CS states is carried out under control of the expert - diagnostician who coordinates decision received neural nets experts, and at revealing unknown faults brings the information in knowledge bases of CS

diagnosing means.

## 7. CONCLUSIONS

1. Using of information models in CS diagnosing means enables to describe state of computer systems in conditions of the incomplete diagnostic information concerning values of parameters and characteristics of hardware and software components. For that is necessary to take into account results of monitoring programs and knowledge of experts-diagnosticians.

2. Artificial neural networks ART2 and SOM provide an opportunity clustering of CS states. Researches have shown that results of CS state clustering by these networks are complementary.

3. The new approach for identification of CS state with use of the union neural nets experts is offered. It provides an opportunity of forecasting of CS state and revealing unknown before faults due to the coordination results of work neural nets experts.

4. The size and structure of information description vector are influence on results of researches, therefore questions of choice optimum quantities, structure and estimations quantity of information in elements of the information description vector are require the further researches.

## 8. REFERENCES

- [1] Pomorova O.V. Computer Devices Diagnostic Method on the Base of the Information Model, *Proc. of the International Conference TCSET'2006 "Modern problems of radio engineering, telecommunications and computer science"*, Lviv, Slavske, Ukraine, February 28-March 4, 2006, pp. 152-154.