

Збільшення частки коректної кластеризації характеристичного сигналу з випадковими втратами на картах самоорганізації

С. І. Шаповалова, Ю. В. Москаленко

Проведено аналіз способів оптимізації алгоритмів функціонування нейронних мереж Кохонена – карт самоорганізації (Self-organizing map – SOM) за швидкістю навчання та часткою коректної кластеризації. Визначено ефективну оптимізацію карт самоорганізації за другим критерієм – Enhanced Self-Organizing Incremental Neural Network (ESOINN). Визначено, що у випадку неповного вхідного сигналу, тобто сигналу з втратами в невідомі моменти часу, частка коректної кластеризації неприпустимо низька на будь-яких алгоритмах SOM, як базових, так і оптимізованих.

Неповний сигнал представлено як вхідний вектор нейронної мережі, значення якого подані єдиним масивом тобто без урахування відповідності моментів втрат поточним значенням і без можливості визначення цих моментів. Запропоновано та програмно реалізовано спосіб визначення відповідності неповного вхідного вектора до вхідного шару нейронів для підвищення частки коректного розпізнавання. Спосіб засновано на пошуку мінімальної відстані між поточним вхідним вектором та вектором-ваг кожного з нейронів. Для зменшення часу роботи алгоритму запропоновано оперувати не окремими значеннями вхідного сигналу, а їх неподільними частинами та відповідними групами вхідних нейронів. Запропонований спосіб реалізовано для SOM та ESOINN. Для доведення ефективності реалізації базового алгоритму SOM проведено його верифікацію з існуючими аналогами інших розробників.

Розроблено математичну модель для формування прикладів повних сигналів навчальної вибірки на основі еталонних кривих другого порядку та сформовано навчальну вибірку. За цією навчальною вибіркою було проведено навчання всіх нейронних мереж, реалізованих з використанням запропонованого способу та без нього. Розроблено схему імітації втрат та згенеровано тестові вибірки для обчислювальних експериментів на неповних сигналах.

На основі експериментів доведено ефективність запропонованого способу для класифікації за неповним вхідним сигналом на основі карт самоорганізації як для реалізації базового алгоритму SOM, так і для ESOINN

Ключові слова: карта самоорганізації, SOM, ESOINN, нейронні мережі Кохонена (Kohonen), сигнал з втратами, втрати в часовому ряді, класифікація за характеристичним сигналом

1. Вступ

Однією з базових задач в системах контролю об'єкту за вхідним сигналом їх характеристик є задача класифікації. Якщо сигнал представляється як

часовий ряд доцільне використання нейронних мереж для забезпечення високого рівня коректності розпізнавання.

При втраті частини сигналу або деяких його значень у невідомі моменти часу неможливо застосовувати різновиди мереж, розмір вхідного шару яких відповідає розміру вхідного вектору. Однак можна використовувати мережі Кохонена, а саме карти самоорганізації (Self-organizing map – SOM). Концептуальною перевагою SOM, в порівнянні з іншими нейронними мережами, є можливість навчання на малій кількості прикладів навчальної вибірки, що є суттєвим для систем автоматичного контролю, особливо для передаварійних режимів роботи обладнання.

Нейронні мережі SOM знайшли широке використання для розв'язання сучасних прикладних задач класифікації за сигналом характеристик в різноманітних галузях, наприклад:

- діагностування якості яблук та насіння кукурудзи на основі динамічного спеклу (dynamic speckle) [1]. Вхідною інформацією SOM є результати дескрипторів стану насіння;

- класифікація астрономічних об'єктів. Вхідними даними SOM є дані космічного телескопу Gaia [2];

- створення виборок локальних галактик після зіркоутворення [3]. Основним джерелом інформації є база даних Sloan Digital Sky Survey (SDSS) – проект дослідження зображень і спектрів красного зміщення зірок і галактик;

- порівняння ансамблів білків [4]. Вхідною інформацією є результати комп'ютерного моделювання ансамблів білків.

В цих прикладах результат представляється візуалізацією SOM у вигляді розфарбованої топографічної карти.

Однак при кластеризації на мережі SOM сигналу з втратами також значно зменшується частка коректного відношення до відповідного класу, що унеможливорює використання цієї мережі при розв'язанні практичних задач, наприклад, пошуку аномалій (anomaly detection). Тому вдосконалення алгоритмів функціонування SOM для розпізнавання сигналу з втратами є актуальною задачею та має практичне значення.

2. Аналіз літературних даних і постановка проблеми

Нейронні мережі Кохонена, зокрема SOM, базуються на концепції самоорганізації [5]. Такі мережі за своєю спеціалізацією пристосовані для візуалізації даних і кластерного аналізу. Перевагами SOM є стійкість до зашумлених даних, швидке навчання, невелика кількість прикладів навчальної вибірки.

Великим недоліком цього типу нейронних мереж є надчутливість до початкового розподілу значень вагів. Вирішення цієї проблеми запропоновано в роботах [6–11]. В роботі [6] запропоновано ефективну схему ініціалізації SOM, яка полягає в тому, що приклади навчальної вибірки, різниця між векторами яких суттєва, спеціально ініціалізуються в різних частинах карти самоорганізації. Результати моделювання довели, що початкова ініціалізація суттєво прискорює навчання. В [7] наведено приклад попередньої ініціалізації вершин

кластерів SOM до основного навчання прикладами, для яких заздалегідь відома приналежність до певного класу. Це дозволило скоротити час навчання та примусово розділити кластери SOM.

Крім вдосконалення за початковою ініціалізацією, оптимізацію алгоритмів SOM здійснюють за такими критеріями: пришвидшення навчання та збільшення частки коректної кластеризації в робочому режимі мережі. Відповідно до цих критеріїв, можна умовно виокремити два підходи до оптимізації алгоритмів SOM.

Перший підхід містить методи, спрямовані на пришвидшення навчання.

Критеріями зупинки традиційного навчання SOM є відсутність помітних змін в вагах нейронної мережі на поточному кроці або досягнення заданої максимальної кількості кроків. В роботі [8] запропоновано новий критерій зупинки навчання – ступінь збереження топології. Оптимізована мережа краще формує кластери, які не є топологічно впорядкованими.

В роботі [9] запропоновано модифікацію алгоритму навчання на великих наборах несхожих даних для прискорення часу навчання. В роботі [10] вдосконалено алгоритм навчання на розріджених даних зі зменшенням потреб в обчислювальних ресурсах.

Використання R і k-d дерев (R-tree, k-d tree) для індексації даних з метою прискорення процесу навчання на багатовимірних наборах даних запропоновано в [11].

Загальним недоліком різновидів нейронних мереж, представлених в роботах [6–11], є відносно низька частка коректного розпізнавання в робочому режимі. Тому другий підхід до оптимізації алгоритмів SOM спрямовано на підвищення частки коректного розпізнавання за рахунок чіткого визначення меж кластерів.

Цей підхід полягає в створенні SOM зі змінюваною структурою, забезпечуючи, наприклад, додатковий простір для нових кластерів. Це реалізується додаванням нових фрагментів решітки SOM, які в публікаціях [12–16] називають ногою, юнітом або кластером. Ногою є нейрон або група нейронів, які створюють новий цілий кластер або його “порцію”, що додається в процесі навчання.

В роботі [12] представлено дві моделі SOM. Перша відповідає базовій концепції Кохонена, за якою виконується навчання без вчителя. Однак задачі розв’язуються за допомогою процесу контрольованого зростання розмірності SOM і видалення нодів. Друга модель є результатом поєднання попередньої з використанням радіальних базисних функцій.

В роботі [13] наведено модель карти самоорганізації, яка додає нову ноду, якщо ваги суттєво відрізняються від наявних в мережі. В роботі [14] описано модифікацію мережі Кохонена Growing Self-Organizing Map (GSOM), яка вирішує проблему вибору оптимальної розмірності карти самоорганізації. Мережа GSOM застосовується для задач нелінійного зменшення розмірності, апроксимації та кластеризації.

В роботі [15] представлено модифікацію карти самоорганізації – Self-Organizing Incremental Neural Network (SOINN). Мережа містить два шари, які

навчаються один за одним. Перший шар використовується для визначення топологічної структури кластерів, другий – для визначення кількості кластерів і виявлення вузлів для них. Перший шар є входним для другого. Схожі нейрони першого шару, які об'єднанні зв'язком, визначають один і той самий клас. Після закінчення навчання першого шару починає навчатися другий шар за подібним алгоритмом. Карта “зростає” в процесі навчання і при цьому менш чутлива до шуму входного сигналу.

В роботі [16] запропоновано карту самоорганізації, яку назвали Enhanced Self-Organizing Incremental Neural Network (ESOINN). В ній усунуто такі недоліки SOINN, як:

- 1) невизначеність моменту зупинки навчання першого шару і початку навчання другого;
- 2) проблема злиття кластерів, які близько розташовані. Мережа ESOINN краще розділяє близькі та частково перекриваючі один одного класи.

Таким чином, ESOINN є оптимальною за точністю розпізнавання SOM, що підтверджується зокрема результатами випробовувань на наборах даних MNIST, наведене в статті [17].

Однак і SOM, і ESOINN не надають достатню частку коректної кластеризації сигналу зі втратами. Проблема виникає тому, що в SOM нейрон-переможець обирається за мінімальною відстанню між поточним входним вектором і вектором ваг даного нейрона. Якщо подається повний сигнал, то розмірність поточного входного сигналу дорівнює розмірності входного шару карти самоорганізації. Таким чином, кожен i -й нейрон входного шару відповідає значенню i -го елемента входного вектора. Якщо входний сигнал неповний (частина сигналу втрачена), тобто розмірність входного вектора не дорівнює розмірності входного шару мережі, значення відповідних індексів входного сигналу і входного шару нейронів не співпадають, помилка зростає і сигнал кластеризується неправильно. Розв'язати проблему має додаткове попереднє визначення відповідності входного сигналу до нейронів входного шару. Тому необхідно провести дослідження та вдосконалити алгоритми функціонування SOM для досягнення коректної класифікації у випадку сигналу з втратами.

3. Мета і задачі дослідження

Метою роботи є збільшення точності розпізнавання входного сигналу з втратами на основі нейромережі SOM.

Для досягнення поставленої мети необхідно вирішити такі задачі:

- розробити спосіб класифікації за характеристичним сигналом з випадковими втратами на основі карт самоорганізації;
- розробити математичну модель для формування прикладів навчальної та тестової вибірок;
- обрати існуючі та розробити власні програмні реалізації SOM за базовим алгоритмом та алгоритмом, доповненим запропонованим способом;
- провести верифікацію запропонованих програмних реалізацій з існуючими аналогами на основі обчислювальних експериментів;

– провести обчислювальні експерименти з розпізнавання неповних вхідних сигналів.

4. Класифікація за характеристичним сигналом з випадковими втратами на основі SOM

4.1. Постановка задачі для нейромережевого комплексу

Задача розпізнавання вхідного сигналу в загальному випадку полягає в визначення відповідності вхідного сигналу

$$\bar{X}_{SOM} = [x_1, x_2, \dots, x_n], \quad (1)$$

де x_i – значення вхідного сигналу в i -й момент часу; до класу a_k , який належить множині:

$$A = \{a_1, a_2, \dots, a_d\}. \quad (2)$$

Складність класифікації полягає в тому, що заздалегідь невідомо, в які моменти часу t_j були втрачені відповідні виміри сигналу x_j . Тобто на вхід SOM подається єдиний масив даних, в якому немає пропусків.

SOM розв'язує тільки задачу кластеризації, тобто визначає кластер SOM, який відповідає поточному вхідному сигналу. Після цього необхідно розв'язати задачу класифікації, тобто визначити відповідність даного кластеру класу a_k . Для розв'язання задачі класифікації найчастіше використовують другу нейронну мережу, наприклад, багатошаровий перцептрон MLP (Multilayer perceptron). На рис. 1 наведено схематичне зображення комплексу SOM та MLP.

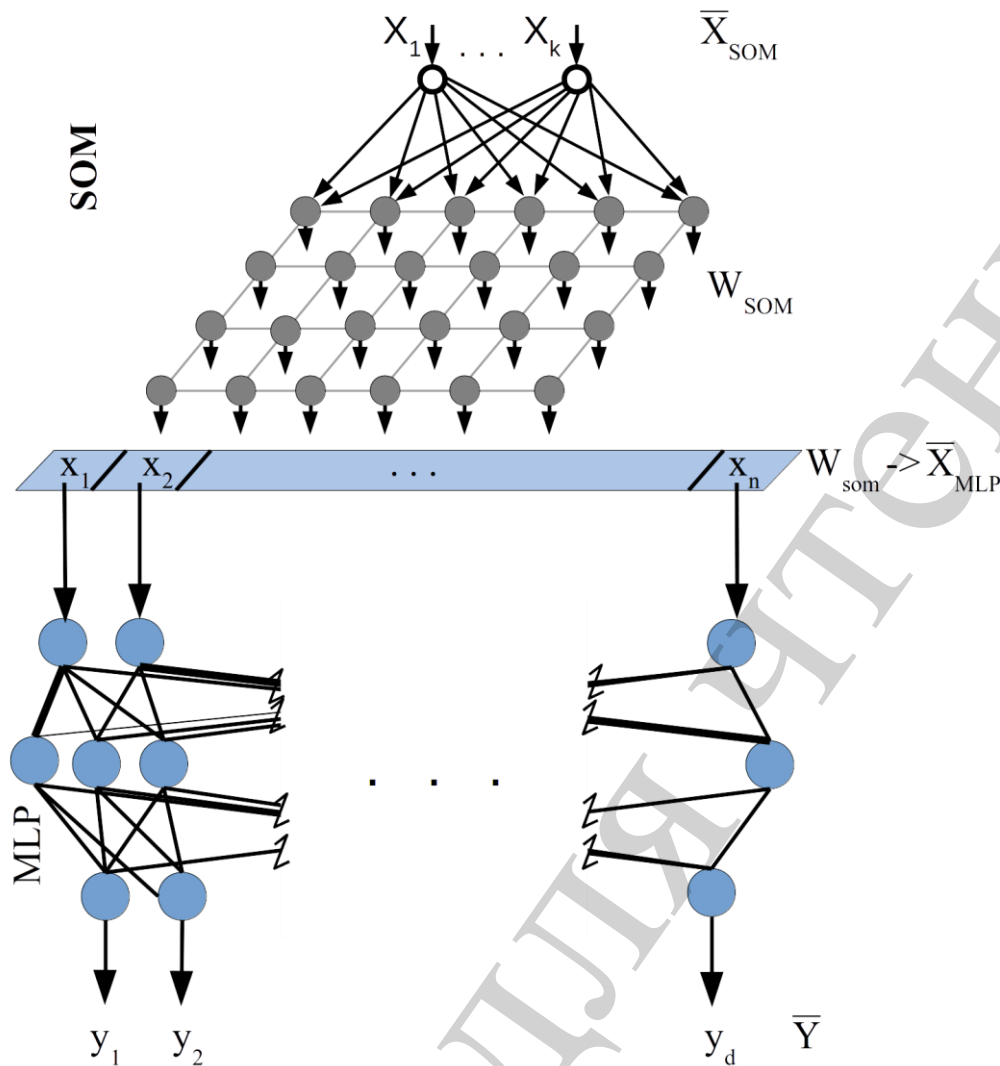


Рис. 1. Розв'язання задачі класифікації на нейронних мережах SOM та MLP

В робочому режимі навчена SOM отримує на вхід сигнал \bar{X}_{som} . Рішення задачі кластеризації полягає у визначенні найбільш відповідного кластеру SOM. Це має відображення на матриці всіх виходів нейронів решітки W_{som} . Для розв'язання задачі класифікації на MLP всі строки матриці W_{som} записуються послідовно і створюють вхідний вектор MLP. Таким чином розмірність вхідного шару MLP залежить від розмірності матриці SOM. Розмірність вихідного шару MLP дорівнює кількості класів розпізнавання прикладної задачі. Кожен нейрон відповідає певному класу a_k з множини A (2). Вихідний вектор MLP Y відображає множину ймовірностей відповідності вхідного вектору до кожного з класів. Результатом розв'язання задачі класифікації є номер нейрона, що визначає розпізнаний клас.

Однак за умови втрати частини характеристичного сигналу, вхідний вектор не відповідає вхідному шару мережі SOM і задача кластеризації розв'язується невірно. Для того, щоб цього уникнути, необхідно здійснити попереднє визначення відповідності вхідного сигналу до нейронів вхідного шару.

4. 2. Визначення відповідності компонентів вхідного вектору нейронам вхідного шару SOM

Проблема коректного розпізнавання за неповним сигналом може бути вирішена на основі попереднього визначення відповідності нейронів вхідного шару нейронної мережі елементам вхідного сигналу. Необхідно встановити відповідності між значенням x_i вхідного сигналу та нейроном n_j вхідного шару нейромережі.

Сигнал представляється як вхідний вектор нейронної мережі, значення якого подаються єдиним масивом, тобто без урахування відповідності моментів втрат поточним значенням і без можливості визначення цих моментів. На рис. 2 схематично показано таку відповідність для повного (рис. 2, а) та неповного (рис. 2, б) вхідних векторів. Якщо на вхід нейроної мережі подається сигнал з втратами, тобто нейронів вхідного шару більше ніж значень \bar{X}_{som} . Таким чином будуть задіяні тільки перші k нейронів вхідного шару, в результаті чого результат розпізнавання буде некоректний.

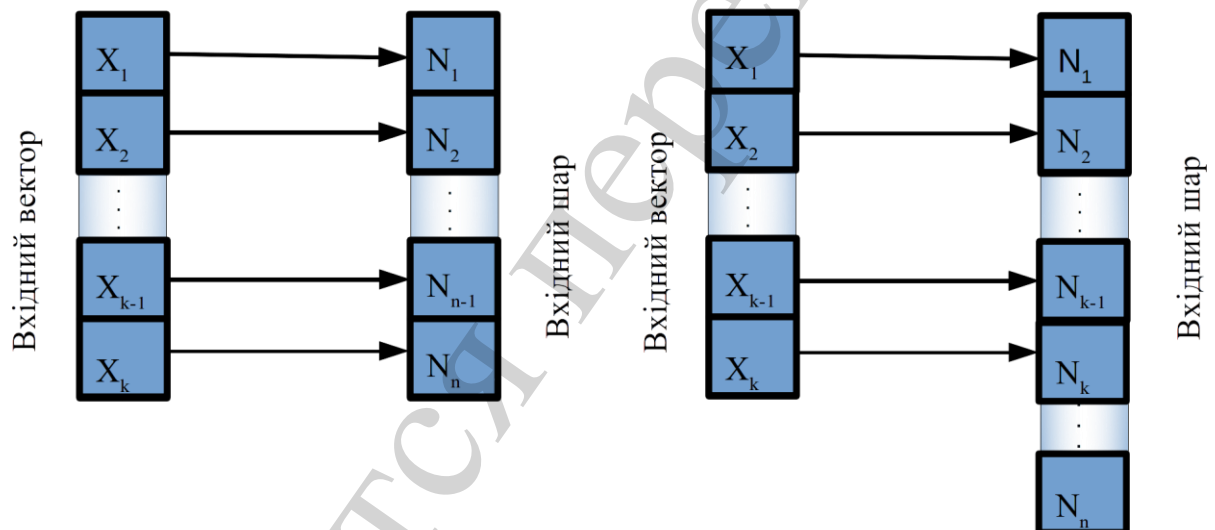


Рис. 2. Відповідність вхідного вектора вхідному шару: а – випадок повного сигналу ($k=n$); б – випадок сигналу з втратами ($k < n$)

Вирішення даної проблеми відбувається визначенням оптимального для поточного сигналу співставлення нейронів вхідного шару вхідному вектору SOM за таким алгоритмом:

1. Встановлення початкової комбінації C_1 співставлення x_i до n_j для всіх k нейронів вхідного сигналу за правилом

$$x_i = n_i. \quad (4)$$

2. Подання \bar{X}_{som} на вхід SOM.

3. Визначення нейрона-переможця за алгоритмом SOM.

4. Перевірка завершення алгоритму:

оскільки кількість задіяних нейронів в SOM дорівнює кількості нейронів вхідного шару, обчислюється поточна помилка нейрона-переможця (без врахування пропущених значень) як Евклідова відстань між вектором його ваг та вхідним сигналом:

$$D = |\bar{X}_{som} - W_j|^2, \quad (5)$$

де \bar{X}_{som} – поточний вхідний вектор SOM; W_j – вектор ваг j -го нейрона-переможця.

Алгоритм завершується в таких випадках:

– якщо поточна помилка менша, ніж задане мінімальне значення помилки δ

$$D < \delta, \quad (6)$$

повертається номер поточного нейрону переможця;

– якщо перебрано всі комбінації співставлення компонентів вхідного вектору та нейронів вхідного шару без виконання умови (6), повертається результат з найменшою помилкою D .

5. Змінення поточної комбінації співставлення C_p на C_{p+1} :

відбувається як один крок перестановки зв'язку x_i до n_j . Для першої ітерації зсув відбувається для $i=k$. З кожною подальшою ітерацією i зменшується на 1.

6. Повернення до п. 2.

В результаті виконання алгоритму співставлення компонентів вхідного сигналу нейронам вхідного шару визначається оптимальна комбінація співставлення. Після цього виконується кластеризація на SOM.

Недоліком даного способу є те, що його обчислювальна складність є факторіальною і залежить від кількості втрачених значень вхідного вектору. Якщо в циклі на ранніх етапах не досягнуто виконання умови (6), то виконується повний перебір відповідності зв'язків компонентів вхідного вектора та нейронів вхідного шару для визначення комбінації з мінімальною похибкою.

Для вирішення проблеми стрімкого зростання обчислювальної складності в роботі запропоновано оперувати не окремими значеннями вхідного сигналу, а їх групами. Пошук відповідності між вхідним шаром і вхідним вектором встановлюється не для кожного значення вхідного вектора, а для групи. Групою нейронів вважається неподільний фрагмент вхідного сигналу з g значень x^g . Цей фрагмент є неподільним з точки зору того, що всі зв'язки та елементи групи відповідають нейронам вхідного шару за принципом:

$$X_i^g = n_j + \text{const}, \quad (7)$$

тобто всі зв'язки в межах групи на кожній ітерації однаково зміщуються на одне значення.

Оптимальний розмір групи g визначається наявними обчислювальними ресурсами і може визначатися експериментально як час, потрачений на класифікацію на тестових прикладах.

Чим менша розмірність групи значень вхідного вектора, тим більша обчислювальна складність. З іншого боку, чим більша кількість компонентів вхідного вектора – тим більшої точності можна досягти.

В проведених обчислювальних експериментах на тестовій задачі визначено, що коректне розпізнавання зберігається при втраті до 20 % вхідного сигналу. Таким чином, при повному вхідному вектору в 100 значень порядок складності алгоритму 10^{20} , а при використанні груп нейронів з початковою розмірністю 7 зменшується в 10^{18} раз.

4. 3. Етапи розв'язання задачі класифікації за неповним сигналом.

1. Реалізація програмного комплексу SOM та MLP за архітектурою, наведеною на рис. 1.

2. Навчання автономної SOM на навчальній виборці з прикладами повного сигналу.

3. Навчання в нейромережевому комплексі MLP за виходом SOM на тій самій навчальній виборці.

4. Визначення відповідності компонентів поточного вхідного сигналу нейронам вхідного шару SOM за запропонованим способом.

5. Класифікація на нейромережевому комплексі SOM – MLP, де SOM приведена у відповідність до поточного неповного сигналу.

Перші три етапи є типовими для класифікації і проводяться один раз. Після цього нейромережевий комплекс готовий класифікувати за повним сигналом. Четвертий етап надає можливість класифікувати неповний сигнал, що здійснюється на п'ятому етапі за алгоритмами функціонування SOM та MLP. Таким чином, класифікація кожного поточного сигналу з втратами у невідомі моменти часу полягає у виконанні двох останніх етапів.

5. Математична модель формування прикладів повних сигналів навчальної вибірки

Тестовий приклад є задачею розпізнавання кривих другого порядку за подібними фрагментами – верхніми частинами кола, еліпса і параболи.

Вхідним сигналом \bar{X}_{som} є перелік дискретних значень функції, що визначає відповідну криву.

Для того, щоб набрати необхідну кількість прикладів навчальної вибірки, до значення x_i відповідної кривої додається значення ε . Це значення належить діапазону $[-1.5*\delta; 1.5*\delta]$, де δ – максимальна відстань між x_i точками, що належать різним еталонним кривим. Значення ε обчислюється як розподілення Гаусса:

$$\varepsilon = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{x^2}{2\sigma^2}}, \quad (8)$$

де параметр $\sigma=0.4$.

Якщо випадкове значення виходить за межі діапазону, то рахуємо $\varepsilon=0$.

Приклади навчальної вибірки розраховуються за формулами (9)–(11):

– для кола:

$$x_i = \sqrt{(R^2 - \tau^2)} + \varepsilon, \quad (9)$$

де x_i – ордината точки в i -ий момент часу; R – радіус кола;

– для еліпса:

$$x_i = \sqrt{(1 - \tau^2 / a_{elips}^2) * b_{elips}^2} + \varepsilon, \quad (10)$$

де a_{elips} , b_{elips} – параметри еліпса;

– для параболи:

$$x_i = a_{parabola} \tau^2 + b_{parabola} + c_{parabola} + \varepsilon, \quad (11)$$

де $a_{parabola}$, $b_{parabola}$, $c_{parabola}$ – параметри параболи.

Для ускладнення задачі обрані подібні фрагменти кривих (рис.4). Еталонні криві задані за такими рівняннями (по 2 криві для кожного класу):

– коло:

$$x_i = \sqrt{(9 - (\tau - 3)^2)} + \varepsilon, \quad (12)$$

$$x_i = \sqrt{(9 - (\tau - 2.9)^2)} + \varepsilon; \quad (13)$$

– еліпс:

$$x = -1/3\tau^2 + 2\tau + \varepsilon, \quad (14)$$

$$x = -1/3\tau^2 + 2.05\tau + 0.1 + \varepsilon; \quad (15)$$

– парабола:

$$x_i = \sqrt{(3 * 3 - \frac{(\tau - 3)^2 * 3^2}{3.2^2})} + \varepsilon, \quad (16)$$

$$x_i = \sqrt{(3 * 3 - \frac{(\tau - 2.95)^2 * 3^2}{3.2^2})} + \varepsilon. \quad (17)$$

На рис. 3 зображені еталонні криві та показано, що діапазон значень x_i з урахуванням випадкової величини ε містить всі можливі значення всіх прикладів, побудованих на основі цих кривих.

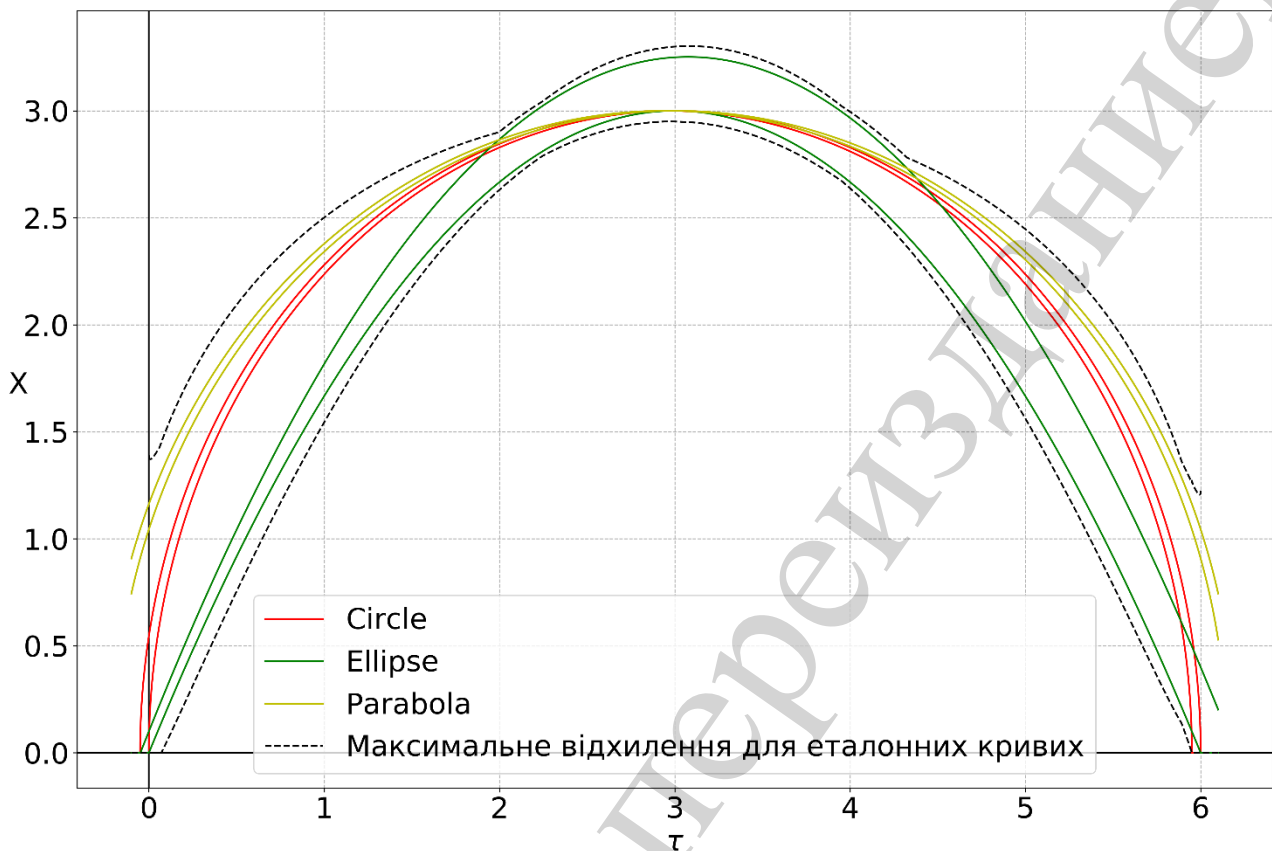


Рис. 4. Еталонні криві тестової задачі

Всі нейронні мережі SOM, які були задіяні в подальших обчислювальних експериментах, проходили навчання на одній і тій самій навчальній вибірці.

6. Реалізації нейронних мереж

Для доведення ефективності запропонованого способу визначення відповідності вхідного вектору до нейронів вхідного шару розроблено такі різновиди нейронних мереж:

- 1) карта самоорганізації SOMbase, реалізована на базовому алгоритмі SOM;
- 2) карта самоорганізації SOMmod – на базовому алгоритмі SOM, доповненому запропонованим способом;
- 3) карта самоорганізації ESOINNmod – на алгоритмі ESOINN, доповненому запропонованим способом;
- 4) багатошаровий перцептрон MLPbase (MLP – Multilayer perceptron) на алгоритмі багатошарового перцептрона.

Перші дві версії SOM реалізовано на одних і тих самих структурах даних та базових алгоритмах для коректного порівняння базового алгоритму SOM з алгоритмом, доповненим запропонованим способом.

Для порівняння результатів розпізнавання на оптимізованих SOM обрано ESOINN з ресурсу [18], на основі якої в мережі ESOINNmod реалізовано запропонований спосіб.

Для тестування досліджуваних мереж Кохонена використовувався розроблений MLPbase, за винятком мереж ENCOG [19] та NeuroPH [20], для яких був використаний MLP з їх бібліотек. Це пов'язано з тим, що SOM розв'язує тільки задачу кластеризації, однак після цього за визначеними кластерами SOM потрібно розв'язати задачу класифікації, тобто визначити, який кластер відповідає якому класу прикладної задачі.

Для верифікації розробленої програмної реалізації SOM за базовим алгоритмом проведено обчислювальні експерименти розпізнавання повного сигналу у порівнянні з існуючими аналогами інших розробників SOM: Encog, NeuroPH. Таким чином доводиться коректність власної реалізації базового алгоритму SOMbase для його подальшого вдосконалення запропонованим способом.

Обчислювальні експерименти з розпізнавання неповних вхідних сигналів проводилися на:

1) мережах SOM без запропонованого способу: SOMbase, NeuroPH, Encog, SOINN, ESOINN, GSOM;

2) мережах SOM з запропонованим способом: SOMMod, ESOINNmod.

Після проведення обчислювальних експериментів порівнювалися частки коректного розпізнавання усіма способами.

Навчання нейронних мереж проводилося за навчальною вибіркою, яка містить 100 прикладів (34 приклади кола, 33 еліпса, 33 параболи). Кожний приклад відтворює повний сигнал, який складається зі 100 значень, обчислених за формулами (8), (12)–(17). Навчалися такі карти самоорганізації: NeuroPH, ENCOG, GSOM, SOINN, SOMbase, ESOINN, SOMmod, ESOINNmod, а також багат шаровий перцепрон MLP. Початкова швидкість навчання для SOM дорівнювала 0.1. Швидкість навчання всіх SOM через перші 200 кроків примусово зменшувалась в 5 разів, а в подальшому зменшувалась ще в 5 разів кожні 50 кроків. Для навчання SOM знадобилося 400 епох.

Початкова швидкість навчання багат шарового перцепрона дорівнювала 0.01 і примусово зменшувалась в 5 разів, якщо на протязі 5 епох не спостерігалось змін в точності класифікації тестової виборки. В подальшому, якщо на протязі 15 кроків не спостерігалось змін похибки, навчання зупинялося.

Для кінцевого розв'язання задачі класифікації матриця виходів всіх нейронів кожної SOM подавалася як послідовність рядків на MLP, який визначав приналежність до відповідного класу. Для мереж Encog, NeuroPH використовувався MLP з їх бібліотек, в решті випадків – MLP власної розробки.

7. Верифікація реалізацій базових алгоритмів SOM та MLP

Перша серія обчислювальних експериментів проводилася для верифікації мережі SOM, розробленої за базовим алгоритмом, з існуючими аналогами, які

поділяються на мережі без оптимізації: Encog [19], NeuroPH [20], та з оптимізацією SOINN [21], ESOINN [18], GSOM [22].

Тестова вибірка, за якою проводилося порівняння, містила повні сигнали вхідного вектора \bar{X} без втрат, окремо згенеровані за формулами (8), (12)–(17).

Оскільки вибірка даних є збалансованою, коректність класифікації можна визначати за метрикою точності (accuracy):

$$Accuracy = \frac{P}{N}, \quad (18)$$

де P – кількість класів, які класифікатор вірно розпізнав; N – розмір навчальної вибірки.

Метою експерименту було визначення частки коректного розпізнавання за повним сигналом кожною нейронною мережею в однакових умовах. В усіх подальших експериментах частка коректного розпізнавання визначалась таким чином:

$$Cor = Accuracy * 100 \%, \quad (19)$$

де Accuracy – метрика точності.

В табл. 1 представлено результати розпізнавання всіх реалізацій SOM, які брали участь в поточному та подальших обчисленнях. Для коректного порівняльного аналізу також зазначено наявність або відсутність оптимізації поточної SOM.

Таблиця 1

Результати порівняння реалізацій SOM за повним сигналом

№ п/п	Назва реалізації SOM	Наявність оптимізації SOM	Частка коректного розпізнавання, %
1	SOMbase	–	80
2	NeuroPH	–	79
3	Encog	–	81
4	SOINN	+	87
5	ESOINN	+	90
6	GSOM	+	86

Таким чином, доведено ефективність власної реалізації базового алгоритму (табл. 1, п. 1–3) та підтверджено, що оптимізовані різновиди SOM на повному сигналі дають кращий результат в порівнянні з нейромережами, реалізованими за базовим алгоритмом (табл. 1, п. 4–6).

8. Обчислювальні експерименти з класифікації за сигналом з випадковими втратами

Друга серія обчислювальних експериментів була призначена для визначення ефективності функціонування SOM за умови втрати сигналу.

Оскільки на ефективність розпізнавання впливає порядок втрат та часові проміжки їх виникнення, поставлено декілька експериментів, які відтворювали різні випадки моментів втрат. З цієї точки зору, задачі розпізнавання було розподілено на такі класи:

1. Втрата єдиної частини сигналу.
2. Втрати значень сигналу в невідомі моменти часу.

Відповідно до цих класів, було згенеровано 4 тестові виборки (перші 3 для першого класу задач та остання – для другого):

1. Втрата послідовних кінцевих значень.
2. Втрата початкових значень.
3. Втрата послідовних значень на заданому проміжку від t_{21} по t_{79} з випадковим початком.
4. Втрата значень сигналу на всьому діапазоні t_1 по t_{100} у випадкові моменти часу.

Для кожної задачі було згенеровано 100 прикладів неповного сигналу. Всі нейронні мережі, які використовувалися в експериментах, були навчені на прикладах повного сигналу. При випробовуваннях в робочому режимі на вхід SOM подавався сигнал з втратами.

В табл. 2 наведено результати тестування за неповним сигналом. Курсивом виокремлено назви нейронних мереж, розробниками яких реалізовано не базовий, а оптимізований алгоритм SOM. В останніх двох стовпцях представлено результати розпізнавання з використанням запропонованого способу базовій реалізації алгоритму – SOMmod та однієї з найкращих оптимізацій за критерієм частки коректного розпізнавання – ESOINNmod.

Таблиця 2
Результати розпізнавання за неповним вектором.

№	Умови задачі		Частка коректного розпізнавання в реалізаціях нейронних мереж, %							
			без запропонованого способу					з запропонованим способом		
	Діапазон втрат в моменти τ_i , де $i=$	Кількість втрачених значень	NeuraPH	ENC OG	GSO M	SOI NN	SOMbase	ESOINN	SOMmod	ESOINNmod
Втрата єдиного фрагменту вхідного сигналу										

1	80–100	5	84	84	85	85	84	93	85	93
		10	82	82	86	86	82	91	83	91
		20	79	81	85	87	82	90	82	90
2	1–20	5	32	32	38	38	32	21	73	77
		10	19	20	35	35	20	17	70	73
		20	16	16	17	14	16	14	66	69
3	1–100	5	48	48	56	58	48	62	77	81
		10	41	41	54	49	41	42	74	77
		20	32	33	35	35	33	38	68	69
Втрати вхідного сигналу в невідомі моменти часу										
4	1–100	5	68	69	69	71	68	74	74	79
		10	54	54	58	60	54	56	61	66
		20	37	37	39	39	37	43	69	71

З точки зору моментів втрат сигналу, найгірше розпізнаються сигнали, в яких втрачено початкові значення.

Результати розпізнавання такого сигналу на всіх оптимізованих та неоптимізованих SOM без реалізацій запропонованого способу були неприпустимо низькі та складали:

- при втраті 5 % сигналу – від 21 % до 38 %;
- при втраті 10 % сигналу – від 19 % до 38 %;
- при втраті 20 % сигналу – від 14 % до 16 %.

Всі мережі найбільш стійкі до втрат кінцевих значень. Приблизно однакові результати показали мережі з запропонованим способом і без нього; точність складала від 79 % до 95 %.

У випадку втрат сигналу на всьому діапазоні з 1-ого по 100-е значення, результат гірший. Однак експерименти показали, що запропонований спосіб значно підвищує частку коректного розпізнавання, особливо при втраті великої кількості значень.

Результати класифікації за неповним сигналом (табл. 2) свідчать про те, що запропонований метод значно збільшує частку коректної кластеризації при неповних вхідних даних. Це стосується як мережі, реалізованої за базовим алгоритмом SOM, так і для оптимізованої мережі, чий алгоритм доповнено запропонованим способом.

9. Обговорення результатів класифікації за неповним вхідним сигналом на основі карт самоорганізації

Запропоновано спосіб визначення відповідності неповного вхідного вектору до вхідного шару нейронів на основі різниці векторів вхідного сигналу і ваг нейронів вхідного шару. Згідно з цим способом, необхідно провести

попереднє визначення комбінації зв'язків між компонентами вхідного вектору та нейронами вхідного шару.

Така попередня підготовка подачі сигналу на нейронну мережу зменшує помилку класифікації. Це відбувається тому, що в SOM примусово активується потрібний кластер. Для цього визначається комбінація відповідності компонентів неповного вхідного вектору нейронам вхідного шару SOM. Таким чином мінімізується відстань між поточним вхідним вектором та вектором ваг активного нейрона за формулою (5), і, відповідно, помилка класифікації.

Запропонований спосіб представлено у вигляді алгоритму, кожен етап якого має необхідні формули та схему для розрахунків. Спосіб дозволяє розв'язати проблему розпізнавання діагностичного сигналу з втратами в невідомі моменти часу.

Для доведення цього способу було запропоновано відповідну тестову задачу. Необхідно було створити задачу класифікації, в якій можна моделювати приклади сигналів у вигляді часових рядів та змінювати моменти втрат їх значень. Для ускладнення постановки задачі класифікації була поставлена умова, що сигнали мають бути схожі за описом настільки, що при імітації шумових значень частково накладаються один на інший. Розв'язанням цього завдання стала математична модель генерації навчальних прикладів за аналітичними рівняннями подібних фрагментів кривих другого порядку (графічне відображення та область перекриття представлено на рис. 4). Навчальна вибірка будується за формулами (8), (12)–(17). Таким чином створено математичну модель імітації зашумлених діагностичних сигналів, за якою можна генерувати навчальну та тестові вибірки для розв'язання складної задачі класифікації.

Для проведення подальших експериментів була розроблена власна реалізація SOM за базовим алгоритмом – SOMbase. Для доведення її ефективності, була проведена верифікація з аналогами інших розробників (табл. 1).

Для обчислювальних експериментів з доведення ефективності запропонованого способу були обрані існуючі програмні реалізації SOM, створені за базовим алгоритмом (NeuraPH, Encog) та з трьома різновидами оптимізації інших розробників: GSOM, SOINN, ESOINN. Дві реалізації SOM – власна SOMbase та одна з найефективніших за часткою коректності розпізнавання ESOINN – були доповнені запропонованим способом. Інші реалізації залишились без змін.

Результати випробувань (табл. 2) довели, що запропонований спосіб значно покращує коректність кластеризації, однак моменти втрат суттєво впливають на його ефективність. При найменш ефективному застосуванні показники залишаються такими самими або незначно кращими (на 1–3 %). В найкращих випадках частка коректного розпізнавання підвищується з 14 % до 69 % на доповненій запропонованим способом нейронній мережі ESOINN.

Таким чином експериментально доведено ефективність запропонованого способу класифікації за неповним сигналом.

Практична значущість роботи полягає в можливості використання запропонованого способу для діагностування стану технічних об'єктів за

часовим рядом їх характеристик. Особливістю є те, що немає необхідності в перетвореннях початкового сигналу та екстракції додаткових характеристик, наприклад частотних. Це затребувано в багатьох прикладних задачах контролю поточних характеристик в реальному часі з можливими втратами сигналу через зовнішні фактори.

Недоліком способу є зростання обчислювальної складності, тобто часу класифікації. Для усунення цього недоліку запропоновано використання груп, що дозволило знизити час класифікації тестової вибірки в 10^{18} раз.

Серед обмежень даного способу є ймовірність неправильної класифікації сигналу з викидами. Саме розпізнавання таких сигналів та підвищення стійкості SOM є перспективою подальших досліджень. Це необхідно, зокрема, для розв'язання задач пошуку аномалій.

10. Висновки

1. Запропоновано та програмно реалізовано спосіб класифікації за характеристичним сигналом з втратами у випадкові моменти часу на основі карт самоорганізації. Існуючу методику класифікації доповнено визначенням відповідності неповного вхідного вектора до вхідного шару нейронів для підвищення частки коректного розпізнавання.

2. Розроблено математичну модель формування прикладів повних сигналів навчальної вибірки на основі еталонних кривих другого порядку. Таким чином доповнено спеціальні тестові задачі для визначення ефективності нейронних мереж за швидкістю та коректністю роботи (dataset). На відміну від існуючих наборів даних, що представляють прикладні задачі, запропонована модель надає можливість моделювати параметри сигналу і розмір областей перетинання класів. Для експериментів з неповним сигналом розроблено схему імітації втрат та згенеровано тестові вибірки. Це дозволило моделювати втрати дискретних значень або цілих фрагментів сигналу в різні моменти часу.

3. Проведено аналіз способів оптимізації алгоритму SOM. Обрано існуючі і реалізації SOM та їх оптимізації для проведення обчислювальних експериментів: ENCOG, NeuroPH, SOINN, GSOM, ESOINN. Визначено ефективну оптимізацію SOM – ESOINN. Для обчислювальних експериментів: розроблено програмні реалізації SOM за базовим алгоритмом та алгоритмом, доповненим запропонованим способом; доповнено програмну реалізацію ESOINN запропонованим способом.

4. Для доведення ефективності реалізації базового алгоритму SOM проведено його верифікацію з існуючими аналогами: NeuroPH, Encog. Доведено, що частка коректної класифікації власної розробки (80 %) відповідає результатам такого самого алгоритму інших розробників (78 % та 81 % відповідно).

5. На основі обчислювальних експериментів доведено ефективність запропонованого способу для класифікації за неповним вхідним сигналом на основі карт самоорганізації як для реалізацій базового алгоритму SOM, так і найефективнішої оптимізації ESOINN. В залежності від моментів втрат частка коректного розпізнавання на доповненій запропонованим способом нейронній

мережі ESOINN в гіршому випадку незначно покращується на 1–3 %; в найкращому випадку підвищується з 14 % до 69 %.

Література

1. Unsupervised learning segmentation for dynamic speckle activity images / Passoni L. I., Dai Pra A. I., Meschino G. J., Guzman M., Weber C., Rabal H., Trivi M. // arXiv. 2014. URL: <https://arxiv.org/abs/1408.3818>
2. An approach to the analysis of SDSS spectroscopic outliers based on Self-Organizing Maps / Fustes D., Manteiga M., Dafonte C., Arcay B., Ulla A., Smith K., Borrachero R., Sordo R. // arXiv. 2013. URL: <https://arxiv.org/abs/1309.2418>
3. A large sample of Kohonen selected E+A (post-starburst) galaxies from the Sloan Digital Sky Survey / Meusinger H., Brünecke J., Schalldach P., in der Au A. // *Astronomy & Astrophysics*. 2017. Vol. 597. P. A134. doi: <https://doi.org/10.1051/0004-6361/201629139>
4. Fraccalvieri D., Bonati L., Stella F. Self Organizing Maps to efficiently cluster and functionally interpret protein conformational ensembles // *Electronic Proceedings in Theoretical Computer Science*. 2013. Vol. 130. P. 83–86. doi: <https://doi.org/10.4204/eptcs.130.13>
5. Kohonen T. Self-organized formation of topologically correct feature maps // *Biological Cybernetics*. 1982. Vol. 43, Issue 1. P. 59–69. doi: <https://doi.org/10.1007/bf00337288>
6. Su M.-C., Liu T.-K., Chang H.-T. Improving the self-organizing feature map algorithm using an efficient initialization scheme // *Tamkang Journal of Science and Engineering*. 2002. Vol. 5, Issue 1. P. 35–48.
7. Шаповалова С. І., Шараєвський Г. І. Комп'ютерне моделювання карти самоорганізації для розв'язання задачі розпізнавання сигналів // *Вісник національного університету “Львівська політехніка”*. 2007. № 574. С. 75–80.
8. Su M.-C., Chang H.-T. Genetic-algorithms-based approach to self-organizing feature map and its application in cluster analysis // *1998 IEEE International Joint Conference on Neural Networks Proceedings. IEEE World Congress on Computational Intelligence (Cat. No. 98CH36227)*. 1998. doi: <https://doi.org/10.1109/ijcnn.1998.682372>
9. El Golli A. Speeding up the self organizing map for dissimilarity data // *Proceedings of International Symposium on Applied Stochastic Models and Data Analysis*. Brest, 2005. P. 709–713.
10. Conan-Guez B., Rossi F., El Golli A. Fast algorithm and implementation of dissimilarity self-organizing maps // *Neural Networks*. 2006. Vol. 19, Issue 6-7. P. 855–863. doi: <https://doi.org/10.1016/j.neunet.2006.05.002>
11. Cuadros-Vargas E., Romero R. F., Obermayer K. Speeding up algorithms of SOM family for large and high dimensional databases // *In Workshop on Self Organizing Maps*. Kitakyushu, 2003.
12. Fritzke B. Growing cell structures – A self-organizing network for unsupervised and supervised learning // *Neural Networks*. 1994. Vol. 7, Issue 9. P. 1441–1460. doi: [https://doi.org/10.1016/0893-6080\(94\)90091-4](https://doi.org/10.1016/0893-6080(94)90091-4)

13. Interconnected growing self-organizing maps for auditory and semantic acquisition modeling / Cao M., Li A., Fang Q., Kaufmann E., Kröger B. J. // *Frontiers in Psychology*. 2014. Vol. 5. doi: <https://doi.org/10.3389/fpsyg.2014.00236>
14. Growing self-organizing map approach for semantic acquisition modeling / Cao M., Li A., Fang Q., Kroger B. J. // 2013 IEEE 4th International Conference on Cognitive Infocommunications (CogInfoCom). 2013. doi: <https://doi.org/10.1109/cogincom.2013.6719269>
15. Furo S., Hasegawa O. An incremental network for on-line unsupervised classification and topology learning // *Neural Networks*. 2006. Vol. 19, Issue 1. P. 90–106. doi: <https://doi.org/10.1016/j.neunet.2005.04.006>
16. Furo S., Ogura T., Hasegawa O. An enhanced self-organizing incremental neural network for online unsupervised learning // *Neural Networks*. 2007. Vol. 20, Issue 8. P. 893–903. doi: <https://doi.org/10.1016/j.neunet.2007.07.008>
17. Алгоритм Улучшенной Самоорганизующейся Растущей Нейронной Сети (ESOINN). URL: <https://habr.com/post/206116>
18. An enhanced self-organizing incremental neural network for online unsupervised learning. URL: <https://github.com/BeIBES/ESOINN>
19. Encog Machine Learning Framework. URL: <https://github.com/encog/encog-java-core>
20. Neuroph – Java Neural Network Platform Neuroph. URL: <https://github.com/neuroph/neuroph>
21. Self-Organizing Incremental Neural Network. URL: <https://github.com/fukatani/soinn>
22. Growing Self-Organizing Map. URL: <https://github.com/philippludwig/pygsom>