

НЕЙРОІНФОРМАТИКА ТА ІНТЕЛЕКТУАЛЬНІ СИСТЕМИ

NEUROINFORMATICS AND INTELLIGENT SYSTEMS

НЕЙРОИНФОРМАТИКА И ИНТЕЛЛЕКТУАЛЬНЫЕ СИСТЕМЫ

УДК 004.896

МЕТОД СТРУКТУРНОГО ДОНАЛАШТУВАННЯ НЕЙРОМЕРЕЖЕВИХ МОДЕЛЕЙ ДЛЯ ЗАБЕЗПЕЧЕННЯ ІНТЕРПРЕТАБЕЛЬНОСТІ

Леощенко С. Д. – аспірант кафедри програмних засобів Національного університету «Запорізька політехніка», Запоріжжя, Україна.

Олійник А. О. – д-р техн. наук, доцент кафедри програмних засобів Національного університету «Запорізька політехніка», Запоріжжя, Україна.

Субботін С. О. – д-р техн. наук, професор, завідувач кафедри програмних засобів Національного університету «Запорізька політехніка», Запоріжжя, Україна.

Гофман Є. О. – канд. техн. наук, старший науковий співробітник науково-дослідної частини Національного університету «Запорізька політехніка», Запоріжжя, Україна.

Корнієнко О. В. – аспірант кафедри програмних засобів Національного університету «Запорізька політехніка», Запоріжжя, Україна.

АНОТАЦІЯ

Актуальність. Розглянуто задачу структурного доналаштування попередньо синтезованих моделей на базі штучних нейронних мереж для забезпечення властивості інтерпретабельності при роботі із великими об'ємами даних. Об'єктом дослідження є процес структурного доналаштування штучних нейронних мереж з використанням адаптивних механізмів.

Мета роботи полягає у розробці методу структурного доналаштування нейронних мереж для підвищення швидкості їх роботи та зменшенні ресурсоемності при обробці великих даних.

Метод. Запропоновано метод структурного доналаштування нейронних мереж на основі адаптивних механізмів запозичених із нейроеволюційних методів синтезу. На початку метод використовує систему індикаторів для оцінки існуючої структури штучної нейронної мережі. Оцінка ґрунтується на структурних особливостях нейромоделі. Потім отримані індикаторні оцінки порівнюються із критеріальними значеннями для вибору типу структурного доналаштування. У якості варіантів структурного доналаштування використовується варіанти мутаційних змін із групи методів нейроеволюційної модифікації топології і ваг нейромережі. Метод дозволяє знизити ресурсоемність під час роботи нейромоделі, за рахунок пришвидшення обробки великих даних, що розширює поле практичного застосування штучних нейронних мереж.

Результати. Розроблений метод реалізовано та досліджено на прикладі використання рекурентної штучної мережі типу Довга короткочасна пам'ять при вирішенні задачі класифікації. Використання розробленого методу дозволило збільшити швидкість роботи нейромоделі з тестовою вибіркою на 25,05%, в залежності від використовуваних обчислювальних ресурсів.

Висновки. Проведені експерименти підтвердили працездатність запропонованого математичного забезпечення і дозволяють рекомендувати його для використання на практиці при структурному доналаштуванні попередньо синтезованих нейромоделей для подальшого вирішення задач діагностування, прогнозування, оцінювання та розпізнавання образів з використанням великих даних. Перспективи подальших досліджень можуть полягати в більш тонкому налаштуванні системи індикаторів для визначення зв'язків, що кодують зачумлені дані з метою додаткового підвищення точності роботи моделей на основі нейронних мереж.

КЛЮЧОВІ СЛОВА: інтерпретабельність, топологія, доналаштування структури, нейроеволюція, нейронні мережі.

АБРЕВІАТУРИ

IoT – Internet of things;

LSTM – Long short-term memory;

OBS – Optimal Brain Surgery;

TWEANN – Topology and Weight Evolving Artificial

Neural Networks;

WANN – Weight Agnostic Neural Networks;

PHM – рекурентна нейронна мережа;

ШНМ – штучна нейронна мережа.

НОМЕНКЛАТУРА

ε – незалежна змінна;

E_{Sample} – функція помилки;
 c – міжнейронні зв'язки ШНМ;
 $crit_{condcompl}$ – критерій умовної складності;
 E – відносна помилка;
 E_{Sample} – помилка моделі на тестовій вибірці;
 $error_{class}$ – помилкові екземпляри;
 $Error_{NN}$ – точність роботи ШНМ;
 $f(w, \varepsilon)$ – математична модель;
 FB_c – зворотні зв'язки у ШНМ;
 FF_c – прямі зв'язки у ШНМ;
 $ind_{activ}^{(\mu, i)}$ – індикатор логічної прозорості i -го нейрона μ -го шару мережі;
 $ind_{deg rconn}$ – індикатор середньої зв'язаності ШНМ;
 $ind_{distrat}$ – індикатор розрідженості зв'язків мережі;
 $ind_{logtransp}$ – індикатор логічної прозорості ШНМ;
 ind_{memor} – індикатор використання пам'яті;
 k – кількість міжнейронних зв'язків у ШНМ;
 L – кількість шарів у ШНМ;
 l – кількість нейронів на вході мережі;
 N_i – множина нейронів на вході мережі;
 N_o – множина нейронів на виході мережі;
 N_h – множина нейронів прихованого шару мережі;
 N_s – загальна кількість нейронів в ШНМ;
 NN – штучна нейронна мережа;
 NN_{param} – мета-параметри (інформація) про мережу;
 NN_{struct} – структура мережі;
 $NumN_{\mu}$ – число нейронів у μ -му шарі ШНМ;
 $NumW^{(\mu, i)}$ – кількість ваг i -го нейрону у μ -му шарі ШНМ;
 $NumW_{w=0}^{(\mu, i)}$ – кількість ваг i -го нейрону у μ -му шарі ШНМ, що дорівнюють 0;
 $Number_{sampler}$ – кількість екземплярів у вибірці;
 p – кількість нейронів на виході ШНМ;
 r – кількість нейронів у прихованому шарі ШНМ;
 $param$ – параметри ШНМ;
 $samp_{Inst}$ – кількість екземплярів у навчальній вибірці;
 $samp_{Feat}$ – кількість ознак у навчальній вибірці
 $struct$ – структура ШНМ;
 $Sample$ – вхідна вибірка даних;
 Val_1 – обмеження на складність ШНМ;
 Val_2 – обмеження на розмірність ШНМ;
 w – сукупність параметрів регресійної моделі;

W_{FBc} – кількість зворотних зв'язків для рекурентних нейромереж ($W_{FBc} = \{w_1, w_2, \dots, w_j\}$);

W_{FFc} – кількість прямих зв'язків нейромережі ($W_{FFc} = \{w_1, w_2, \dots, w_i\}$);

$W_{w=0}$ – ваги зв'язків, що дорівнюють нулю.

ВСТУП

Впровадження технологій, на кшталт: IoT, віддалених сенсорних систем та мереж допомагає промисловостям підвищити ефективність [1–5], проте можливості аналізувати величезні обсяги наявних даних саме тоді, коли це необхідно – в режимі онлайн, залишаються значно обмеженими. Зазвичай це обумовлено складнощами з обробкою великих даних в реальному часі [6]. Предобробка даних може іноді займати занадто багато часу і так само бути досить ресурсоємною. Тому варто звернути увагу на саму модель, яка використовується для роботи.

Завдання пошуку оптимальної структури нейронної мережі тісно пов'язана з проблемами недонавчання та перенавчання [6–8]. Занадто прості мережі не здатні адекватно моделювати цільові залежності в реальних завданнях. Занадто складні мережі мають надлишкове число вільних параметрів, які в процесі навчання налаштовуються не тільки на відновлення цільової залежності, але і на відтворення шуму [9, 10].

В роботі автори пропонують метод структурної оптимізації, що ґрунтується на адаптивних механізмах нейроevolюційних підходів для пошуку найбільш оптимальної структури ШНМ, що використовується у якості моделі при обробці даних.

Об'єкт дослідження – процес структурного доналаштування ШНМ.

Існуючі методи структурного доналаштування синтезованих нейромоделей характеризуються низкою недоліків [6–8]. Для деяких методів ці недоліки обумовлені необхідністю обрахунку додаткових метапараметрів, що значно підвищує вимоги до обчислювальних ресурсів. Для інших методів недоліки пов'язані із вузькою областю специфічних задач відповідних нейромоделей.

Предмет дослідження – метод структурного доналаштування ШНМ.

На сьогоднішній день існує група методів нейроevolюційного підходу, що одночасно виконують модифікацію топології та параметрів нейромоделі – TWEANN [11, 12]. Проте, загальний процес синтезу нової ШНМ може бути занадто ресурсоємним та недоречним. Тому, у роботі запропоновано підхід, що базується на використанні мутаційних змін та специфічних індикаторів і критеріїв для структурного доналаштування вже попередньо синтезованих ШНМ.

Мета роботи – розробка методу структурного доналаштування ШНМ для підвищення швидкості їх роботи та зменшення ресурсоємності при обробці великих даних.

1 ПОСТАНОВКА ПРОБЛЕМИ

Нехай маємо попередньо синтезовану нейромодель NN із визначеною структурою та значеннями параметрів $NN = (struct, param)$. Структура $struct = \{N, c\}$, $N = \{N_i, N_h, N_o\}$, $c = \{c\}$ – визначена сукупністю нейронів $N = \{N_i, N_o, N_h\}$, що складається із підмножин вхідних $N_i = \{N_{i_1}, N_{i_2}, \dots, N_{i_l}\}$, $l = 1, 2, \dots, |N_i|$, вихідних $N_o = \{N_{o_1}, N_{o_2}, \dots, N_{o_p}\}$, $p = 1, 2, \dots, |N_o|$ та прихованих нейронів $N_h = \{N_{h_1}, N_{h_2}, \dots, N_{h_r}\}$, $r = 1, 2, \dots, |N_h|$ та множини ваг $w = \{w_k\}$ зв'язків $c = \{c_1, c_2, \dots, c_k\}$, $k = 1, 2, \dots, |c|$ між нейронами.

Тоді задача структурного доналаштування ШНМ полягає в тому, щоб внести структурні зміни до існуючої структури мережі $struct' = \{N', c'\}$, $N' = \{N'_i, N'_h, N'_o\}$, $c' = \{c'\}$ таким чином, щоб збільшити рівень її інтерпретабельності $crit_{condcompl} \rightarrow 1$, за умови, що точність роботи не зменшується $Error_{NN'} \leq Error_{NN}$.

2 ОГЛЯД ЛІТЕРАТУРИ

Останні дослідження Бостонських науковців довели, що впродовж сну (особливо, глибокого сну) у людському мозку відбуваються процеси очищення, або «brainwashed» [13–15]. Загалом можна відмітити, що дослідження довели, що під час сну мозок проводить процеси впорядкування набутої інформації за рахунок скорочення, видалення або додавання нових зв'язків між нейронами. Роботи засвідчили, що під час сну нейрони зменшуються в розмірах і між ними виникають простору, які заповнюються мозковою рідиною. Результати спостережень вчених засновані на відкритті так званої глімфатичної системи, яка діє в мозку спеціально для видалення шкідливих речовин [14, 15]. Клітини мозку-можливо, гліальні клітини, які оточують і підтримують нейрони, зіщулюються під час сну. Це призводить до збільшення міжклітинного простору в речовині мозку, що в свою чергу підсилює приплив рідини, яка виносить з мозку токсини [14, 15]. Тож, припущення про те, що схожі методи оптимізації структури штучних ШНМ зможуть вирішити ряд існуючих проблем не є безрунговим (рис. 1).

OBS – метод спрощення структури регресійної моделі, наприклад, ШНМ [16, 17]. Основна ідея OBS полягає в тому, що ті елементи моделі або ШНМ, які мають малий вплив на помилку апроксимації, можна виключити з моделі без значного погіршення якості апроксимації [16, 17].

Детально представити метод OBS можна наступним чином. Нехай задана вибірка $Sample$, модель $f(w, \varepsilon)$. Для спрощення структури регресійної моделі виконуються наступні кроки [16, 17]:

1) налаштуємо модель, отримуємо параметри $w^* = \arg \min(E_{Sample}(w | f, Sample))$;

2) для прирощення $w^* + \Delta w$ вирішуємо оптимізаційну задачу, знаходимо для кожного індексу i мінімальне значення Лагранжиана L_i ;

3) обираємо серед L_i мінімальне, відсікаємо елемент моделі, відповідний i -му параметру;

4) додаємо до вектора параметрів w^* , вектор прирощень Δw , відповідний відсіченому параметру;

5) отримуємо спрощену модель. Модель переналаштовувати не потрібно;

6) процедуру можна повторювати до тих пір, поки значення помилки не перевершить заздалегідь задане.

Регуляризація в машинному навчанні – метод додавання деяких додаткових обмежень до умови з метою вирішити некоректно поставлене завдання або запобігти перенавчанню [18, 19]. Ця інформація часто має вигляд штрафу за складність моделі. Наприклад, це можуть бути обмеження гладкості результуючої функції або обмеження за нормою векторного простору [18, 19]. З байєсівської точки зору багато методів регуляризації відповідають додаванню деяких апріорних розподілів на параметри моделі. Найчастіше виділяють [18, 19]:

1) L_1 -регуляризацію, або регуляризація лассо-регресією;

2) L_2 -регуляризацію, або регуляризація регресією Ріджа.

В основі L_1 -регуляризації лежить досить проста ідея. Як і у випадку L_2 -регуляризації, ми просто додаємо штраф до початкової функції витрат. Подібно до того, як в L_2 -регуляризації ми використовуємо L_2 -нормування для поправки вагових коефіцієнтів, в L_1 -регуляризації ми використовуємо спеціальне L_1 -нормування. L_2 -регуляризація допомагає вирішити проблему перенавчання моделі [18, 19]. Суть в тому, що надто важкі вагові коефіцієнти відштовхують лінію найкращої відповідності, побудовану на основі мінімізації квадрата помилок, від основної тенденції. L_1 -регуляризація сприяє розрідженості функції, коли лише деякі фактори не дорівнюють нулю. L_2 -регуляризація сприяє появі малих вагових коефіцієнтів моделі, але не сприяє їх точній рівності нулю [18, 19].

WANN – це архітектура ШНМ, представлена розробниками Google, здатна імітувати вроджені інстинкти і рефлексії живих істот, з подальшим донавчанням протягом життя [20, 21]. А також може значно зменшує кількість зв'язків всередині мережі, підвищуючи тим самим їх швидкодію.

Загальна схема роботи методу дуже схожа на нейроревольюційні методи синтезу ШНМ [20, 21]:

1) створюється популяція простих ШНМ;

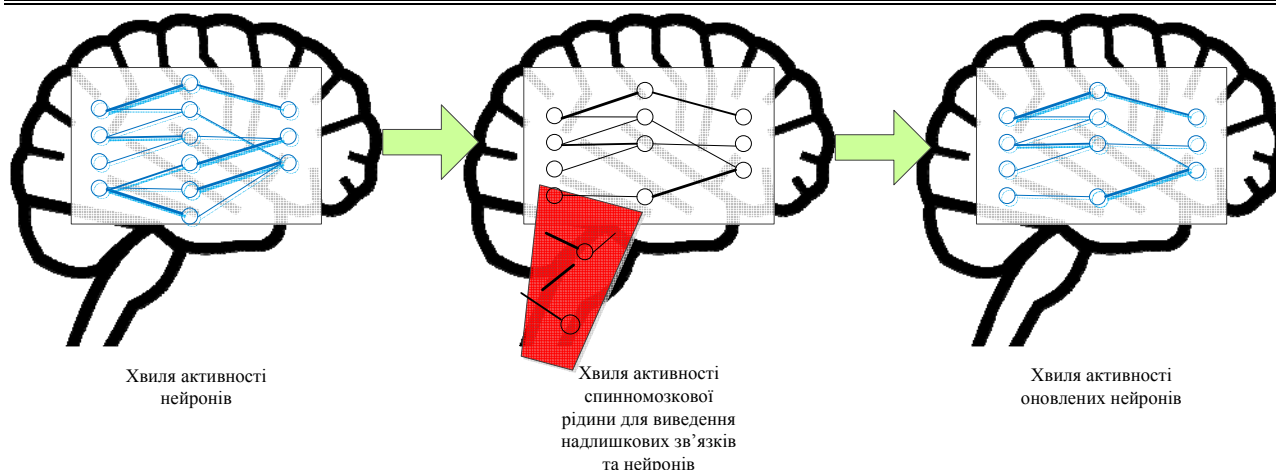


Рисунок 1 – Хвильоподібний процес впорядкування та очищення мозку [13]

2) кожна мережа ініціалізує всі свої ваги одним числом, причому для широкого діапазону чисел: $w = -2 \dots + 2$;

3) отримані мережі сортуються за якістю рішення задачі і за кількістю нейронів (у бік зменшення);

4) у частині кращих представників додається один нейрон, один зв'язок або змінюється функція активації в одному нейроні;

5) ці модифіковані мережі використовуються в якості початкових для нової ініціалізації – так метод повертається до першого кроку.

При порівнянні цих методів та підходів можна зробити наступні висновки: порівняння усі сучасні методи структурної оптимізації ШНМ мають низку недоліків. Так OBS та методи Регуляризації мають хороше теоретичне обґрунтування та використовуються вже достатньо давно, проте слід зазначити, що ці методи вимагають додаткових обрахунків мета-параметрів про ШНМ. Більш того, варто зазначити, що ці обрахунки значно підвищують ресурсоемісність: значно підвищуються вимоги до пам'яті та обчислювальних потужностей – у майбутньому це може призвести до неможливості або слабкої продуктивності паралельних модифікацій цих методів. Також важливо пам'ятати про складність застосування регуляризації для специфічних задач, адже для цих методів дійсно важлива – похідна функції. Похідна, є ключовою, оскільки методи базуються на градієнтному спуску, який в основному рухається в напрямку похідної. При квадратичному члені чим ближче величина знаходиться до нуля, тим меншою стає похідна, поки також не наблизиться до нуля. Тому в такій ситуації зміни при Регуляризації будуть неістотними. Найважливішою ж рисою є те, що OBS та методи Регуляризації майже неможливо застосовувати для структурної оптимізації ШНМ із складними структурами: рекурентні ШНМ зі зворотними зв'язками або глибокі ШНМ із декілька ми прихованими шарами нейронів. З іншого боку, WANN виграють через те, що можуть поступово змінювати топологію ШНМ та налаштовувати її відповідно до задачі. Також слід відзначити значну

перевагу WANN за рахунок того, що немає необхідності зберігати та обраховувати мета-параметри мережі. Проте через недостатнє теоретичне обґрунтування ця технологія поки що нерозповсюджена.

3 МАТЕРІАЛИ ТА МЕТОДИ

Нейроеволюційні методи передбачають використання специфічних генетичних операторів [11, 22, 23]. В ряді робіт пропонувалося використовувати адаптивні механізми мутації. Загалом визначимо основні види мутацій, що можуть використовуватися при синтезі ШНМ [22, 23]:

1) додавання прихованого нейрона. Новий нейрон додається разом з вхідним і вихідним зв'язками. При цьому вихідний зв'язок нейрона не може його зв'язувати із вхідним нейроном;

2) видалення випадково обраного прихованого нейрона разом з усіма вхідними і вихідними зв'язками. При цьому якщо утворюється пробіл в індексах нейронів, що залишилися, то проводиться корекція індексів. Вхідні та вихідні нейрони мережі не можуть бути видалені;

3) додавання зв'язку. Випадковим чином визначаються індекси початкового і кінцевого нейронів в ШНМ, представленої мутуючої особиною. При цьому зв'язок не може закінчуватися вхідним нейроном. Вага зв'язку визначається також випадково з діапазону $[-0,5; 0,5]$: $w_i = \text{Rand} [-0,5; 0,5]$. Якщо в мережі вже існує зв'язок з аналогічними вхідними і вихідними нейронами, то його вага замінюється на випадкову;

4) видалення випадково обраного зв'язку. При цьому може виникнути ситуація, коли видалається останній зв'язок у прихованого нейрона. У цьому випадку нейрон також видалається, і, якщо необхідно, проводиться корекція індексів нейронів мережі;

5) зміна функції активації випадкового прихованого нейрону.

Таким чином, за допомогою мутації можна точно змінювати параметри структури ШНМ.

Тож зазначимо, що таким чином схожі механізми можуть використовуватися для оптимізації структури попередньо синтезованих ШНМ. Саме тому пропону-

ється використовувати адаптивний механізм мутації проте з певними додатковими установками. Хаотичне додавання (видалення) нейронів і зв'язків може призвести до ситуацій, коли, наприклад, в мережі багато нейронів і мало зв'язків. Більш логічним буде застосовувати різні види мутацій в залежності від особливостей архітектури мережі, представленої мутуючої особиною. Для цього буде введено критерії та індикатори, для оцінювання та регуляції розміру та напрямку розвитку мережі.

Використання першого критерію засновано на припущенні, що чим більше елементів в сумі у вхідному та вихідному векторі навчальної вибірки (чим більшою є сумарна кількість вхідних і вихідних нейронів), то, ймовірно, більш складна мережа необхідна для вирішення поставленого завдання. Обчислюється другий коефіцієнт за такою формулою [24–28]:

$$crit_{condcompl} = \frac{N_i + N_o}{N_s}. \quad (1)$$

Тобто, чим більше буде нейронів у мережі, тим меншим буде значення критерію $crit_{condcompl}$ і з тим меншою ймовірністю буде обрана мутація, що додає новий прихований нейрон [24–28].

Перший же індикатор буде використовуватися для оцінки надмірності використаної пам'яті. Як було зазначено вище, нейромережі володіють пам'яттю, що реалізується вагами зв'язків [24–28]. Чим менше пам'ять мережі, тим менше образів вона може запам'ятати. Проте, в ситуації коли дві мережі з різним об'ємом пам'яті забезпечують необхідну точність розпізнавання (оцінювання), то мережа з меншою пам'яттю, звісно має кращі узагальнюючі властивості. Надмірність пам'яті мережі будемо характеризувати за допомогою коефіцієнта надмірності для зберігання навчальної вибірки [24–28]:

$$ind_{memor} = \frac{W_{FFc} + W_{FBc}}{samp_{Inst} \cdot samp_{Feat}}. \quad (2)$$

Якщо $ind_{memor} > 1$, то пам'ять мережі надлишкова (розмірність пам'яті мережі більше розмірності навчальної вибірки). Якщо $ind_{memor} = 1$, то мережа може запам'ятати всю навчальну вибірку (розмірність пам'яті мережі дорівнює розмірності навчальної вибірки). Якщо $ind_{memor} < 1$, то мережа не зможе в точності запам'ятати всю навчальну вибірку (розмірність пам'яті мережі менше розмірності навчальної вибірки), однак при цьому мережа буде проявляти узагальнюючі та апроксимуючі здібності [24–28].

Логічна прозорість мережі в значній мірі залежить від загальної кількості зв'язків в мережі і кількості зв'язків, що з'єднують конкретні нейрони (кількості входів нейронів прихованих шарів) [24–28]. Чим менше зв'язків, тим простіше мережа і тим зручніше вона для аналізу та інтерпретації людиною. Тож індикатор

розрідженості зв'язків мережі прямого поширення визначимо за формулою [24–28]:

$$ind_{distrat} = \frac{W_{w=0}}{\sum_{\mu=1}^L NumN_{(\mu-1)} NumN_{\mu}}, \quad (3)$$

де $0 \leq W_{w=0} \leq \sum_{\mu=1}^L NumN_{(\mu-1)} NumN_{\mu}$.

Індикатор середньої зв'язаності нейронної мережі показує середню кількість входів нейронів всіх шарів, крім першого [24–28].

Індикатор логічної прозорості i -го нейрона μ -го шару мережі $ind_{activ}^{(\mu,i)}$ буде визначатися типом використовуваної функції активації [24–28]. Для лінійної та порогової функції активації приймемо: $ind_{activ}^{(\mu,i)} = 1$, для всіх інших функцій активації $ind_{activ}^{(\mu,i)} = 0$.

$$ind_{deg rconn} = \frac{1}{\sum_{\mu=2}^L NumN_{\mu}} \times \sum_{\mu=2}^L \sum_{i=1}^{NumN_{\mu}} (NumW^{(\mu,i)} - NumW_{w=0}^{(\mu,i)}). \quad (4)$$

Виходячи з цього, коефіцієнт логічної прозорості ШНМ $ind_{logtransp}$ будемо розраховуватися так [24–28]:

$$ind_{logtransp} = \frac{\sum_{\mu=1}^L \sum_{i=1}^{NumN_{\mu}} ind_{activ}^{(\mu,i)}}{ind_{deg rconn} \sum_{\mu=1}^L NumN_{\mu}}, \quad (5)$$

$ind_{deg rconn} \neq 0$.

На рис. 2 представлено у схематичному вигляді процес вибору типу мутації. На рис. 2 використовуються такі позначення: Val_1 та Val_2 – певні граничні значення, що визначаються для завдання. Умовно процес вибору типу мутації можна розділити на дві гілки по першому умовному переходу.

4 ЕКСПЕРИМЕНТИ

Для експериментального дослідження результатів використання запропонованого методу оптимізації структури ШНМ проведемо ряд тестувань. На рис. 3 наведено приклад рекурентної ШНМ. Як видно з рисунку структура ШНМ є надмірною, зазвичай в таких мережах є нульові ваги у деяких синопсисів.

Для роботи будемо використовувати вибірку даних – Набір даних про ускладнення інфаркту міокарда [29–31]. Проблеми реальної складності необхідні для

тестування і порівняння різних методів інтелектуального аналізу даних і розпізнавання образів. Пропонується вибірка може бути використана для вирішення практично важливого завдання: прогнозування ускладнень інфаркту міокарда на основі інформації про пацієнта на момент надходження і на третій день госпітального періоду [29–31].

Інфаркт міокарда – одна з найскладніших проблем сучасної медицини [29–31]. Гострий інфаркт міокарда

пов'язаний з високою смертністю в перший рік після нього. Захворюваність їм залишається високою у всіх країнах. Особливо це стосується міського населення високорозвинених країн, яке піддається впливу хронічних стресових факторів, нерегулярного і не завжди збалансованого харчування [29–31]. У Сполучених Штатах, наприклад, більше мільйона людей щорічно страждають від інфаркту, і 200–300 тисяч з них помирають від гострого ІМ до прибуття в лікарню [29–31].

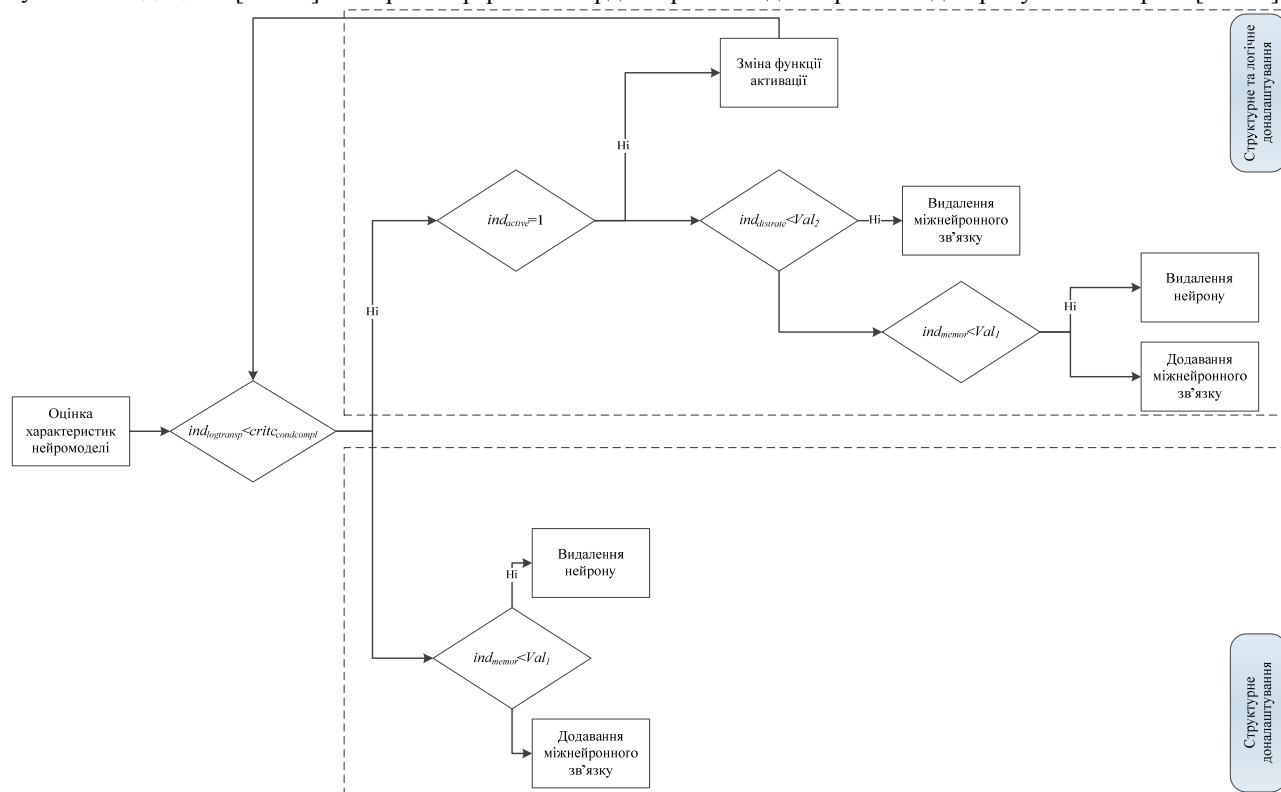


Рисунок 2 – Схематичне зображення процесу вибору типу мутації




Рисунок 3 – ШНМ до оптимізації

Перебіг захворювання у пацієнтів з інфарктом відбувається по-різному. Може протікати без ускладнень або з ускладненнями, які не погіршують довгостроковий прогноз. У той же час близько половини хворих в гострому і підгострому періодах мають ускладнення, які призводять до загострення захворювання і навіть смерті. Навіть досвідчений фахівець не завжди може передбачити розвиток цих ускладнень. У зв'язку з цим прогнозування ускладнень інфаркту міокарда з метою своєчасного проведення необхідних профілактичних заходів є важливим завданням.

Характеристики набору даних у таблиці 1.

Таблиця 1 – Загальна характеристика вибірки даних Myocardial infarction complications Data Set

Характеристика вибірки	багато-вимірна	Кількість екземплярів	1700
Характеристика атрибутів	дійсні	Кількість атрибутів	124

Під час тестування будемо звертати увагу на час роботи мережі та розподіл часу за ітераціями. Додатково будемо оцінювати точність роботи [22, 23]. Для цього введемо відносну помилку, яка в цьому випадку буде обчислюватися, як відношення кількості невірно діагностованих об'єктів до загального розміру вибірки (кількості її екземплярів):

$$E = \frac{error_{class}}{Number_{sampl}} \cdot 100\% . \quad (6)$$

Точність роботи – не є цільовим параметром, проте важливо, щоб оптимізація не погіршала цього значення.

5 РЕЗУЛЬТАТИ

У таблиці 2 наведено порівняння результатів роботи для звичайної мережі та мережі після оптимізації.

Таблиця 2 – Порівняння результатів роботи

	Час роботи, с	Помилка, %
Звичайна мережа	7621	4,2
Оптимізована мережа	5712	3,4

На рис. 4 наведено графік, що демонструє різницю у розподілі часу між ітераціями під час роботи ШНМ.

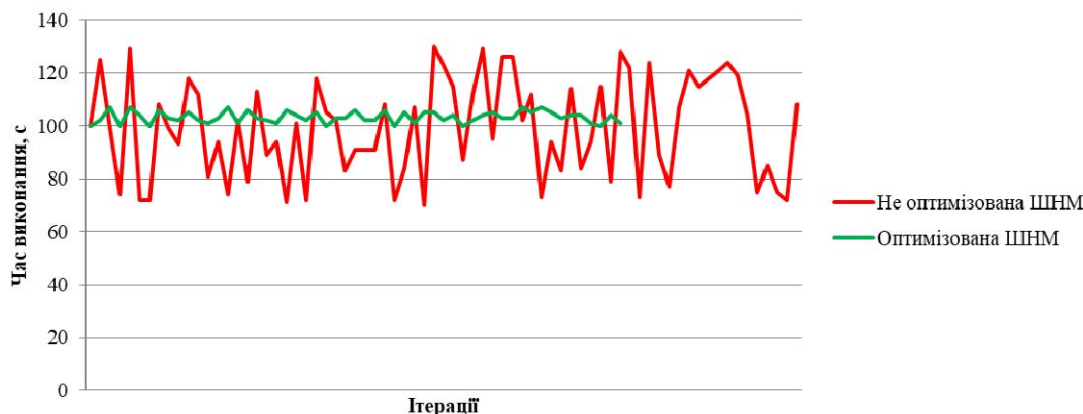


Рисунок 4 – Розподіл часу між ітераціями

6 ОБГОВОРЕННЯ

З таблиці 2 видно, що час роботи значно скоротився. Це пояснюється тим, що оптимізована мережа не задіює зайві синописи та нейрони, що значно пришвидшує роботу із нею. Також важливим є те, що точність роботи оптимізованої мережі зросла. Такий ефект можна пояснити тим, що надмірна структура мережі має надлишкове число вільних параметрів, які в процесі навчання налаштовуються не тільки на відновлення цільової залежності, але і на відтворення шуму, що може впливати на точність роботи.

Під час аналізу графіка можна зробити висновок, що як раз надмірна топологічна складність мережі до оптимізації призводить до різких стрибків у часі між ітераціями. У той же час графік розподілу для оптимізованої мережі більш плавний. І хоча певні стрибки все ж є, їх вплив значно менше та частково його можна списати на особливості складної рекурентної архітектури мережі.

Також варто зазначити, що спрощення структури ШНМ впливає і на ресурсоемістність, а саме на використання пам'яті. Зазвичай, найбільше пам'яті вимагає процес серіалізації ваг синописів. Оскільки оптимізована структура має меншу кількість нейронів та зв'язків між ними – це скорочує витрати пам'яті на збереження мережі.

ВИСНОВКИ

Вирішено актуальну науково-прикладну проблему структурного доналаштування синтезованих ШНМ.

Наукова новизна полягає в тому що розроблено метод структурного доналаштування синтезованих ШНМ на основі нейроволюційного підходу з використанням системи індикаторів та критеріїв для адаптивного визначення мутаційних змін. У запропонованому методі використовуються система індикаторів для оцінки існуючої структури ШНМ. Враховуючи отриману оцінку за структурними особливостями та спираючись на критеріальні значення, обирається тип структурного доналаштування. У якості варіантів структурного доналаштування використовується варіанти мутаційних змін із групи методів нейроволюційної модифікації топології і ваг нейромережі.

Запропонований метод дозволяє знизити ресурсоємність під час роботи нейромоделі, за рахунок пришвидшення обробки великих даних.

Практична цінність полягає в тому, що розв'язано практичні завдання структурного доналаштування та спрощення попередньо синтезованих ШНМ, які можуть використовуватися для діагностування, прогнозування, оцінювання та розпізнавання образів. Більш того, враховуючи полегшену структуру такі нейромоделі можна використовувати при роботі з великими об'ємами вхідних даних. Результати експериментів показали, що запропонований метод дозволяє більш прорідити ШНМ для її подальшого використання у якості моделі для діагностування, прогнозування, оцінювання та моделювання.

Перспективи подальших досліджень полягають у розробці, дослідженні та імплементації критеріальної системи, що дозволить більш тонко оцінювати структурні елементи, що кодуєть зашумлені дані та їх зв'язки. Це дозволить додатково зменшити обчислювальні вимоги та збільшити точність роботи ШНМ, що в свою чергу значно розширить коло практичного використання нейромоделей.

ПОДЯКИ

Робота була проведена за підтримки держбюджетних науково-дослідницьких проектів державного бюджету Національного університету «Запорізька політехніка» «Інтелектуальні методи та програмне забезпечення для діагностики та неруйнівного контролю якості військової та цивільної техніки» (номер державної реєстрації 0119U100360) та «Розроблення методів та засобів для аналізу та прогнозування динамічної поведінки нелінійних об'єктів» номер державної реєстрації 0121U107499).

ЛІТЕРАТУРА / LITERATURA

1. Veneri G. Hands-On Industrial Internet of Things: Create a powerful Industrial IoT infrastructure using Industry 4.0 / G. Veneri, A. Capasso. – Birmingham : Packt Publishing, 2018. – 556 p.
2. Roshak M. Artificial Intelligence for IoT Cookbook: Over 70 recipes for building AI solutions for smart homes, industrial IoT, and smart cities / M. Roshak. – Birmingham : Packt Publishing, 2021. – 260 p.
3. Practical IoT Hacking: The Definitive Guide to Attacking the Internet of Things / [F. Chantzis, I. Stais, P. Calderon et al.]. – San Francisco : No Starch Press, 2021. – 464 p.
4. Nam C. S. Neuroergonomics: Principles and Practice (Cognitive Science and Technology) / C. S. Nam. – Berlin : Springer, 2020. – 492 p.
5. Intelligent Systems and Learning Data Analytics in Online Education (Intelligent Data-Centric Systems: Sensor Collected Intelligence) / [S. Caballé, S. N. Demetriadis, E. G.-Sánchez, P.M. Papadopoulos, A. Weinberger]. – Cambridge : Academic Press, 2021. – 424 p.
6. Aggarwal C. C. Neural Networks and Deep Learning: A Textbook / C. C. Aggarwal. – Berlin : Springer, 2018. – 520 p.
7. Shikhman V. Mathematical Foundations of Big Data Analytics / V. Shikhman, D. Müller. – Berlin : Springer, 2021. – 288 p.
8. Deitel P. Intro to Python for Computer Science and Data Science: Learning to Program with AI, Big Data and The Cloud / P. Deitel, H. Deitel. – London : Pearson, 2019. – 880 p.
9. D'souza R. N. Structural Analysis and Optimization of Convolutional Neural Networks with a Small Sample Size / R. N. D'souza, P.Y. Huang, F.C. Yeh // Scientific Reports. – 2020. – № 10. – P. 1–13. DOI: 10.1038/s41598-020-57866-2.
10. Nowakowski G. Neural Network Structure Optimization Algorithm / G. Nowakowski, Y. Dorogyy, O. Dorogai-Ivaniuk // Journal of Automation, Mobile Robotics and Intelligent Systems. – 2018 – № 12. – P. 5–13. DOI: 10.14313/JAMRIS_1-2018/1.
11. Iba H. Evolutionary Approach to Machine Learning and Deep Neural Networks: Neuro-Evolution and Gene Regulatory Networks / H. Iba. – New York : Springer, 2018. – 258 p.
12. Committee of SGTm Neural-Like Structures with RBF kernel for Insurance Cost Prediction Task / [I. Izonin, R. Tkachenko, N. Kryvinska et al.] // 2nd Ukraine Conference on Electrical and Computer Engineering (UKRCON), 2–6 July 2019 : proceedings. – Lviv : IEEE, 2019. – P. 1037–1040. DOI: 10.1109/UKRCON.2019.8879905.
13. Coupled electrophysiological, hemodynamic, and cerebrospinal fluid oscillations in human sleep / [N. E. Fultz, G. Bonmassar, K. Setsompop et al.] // Science. – 2019. – Vol. 366, Issue 6465. – P. 628–631. DOI: 628–631. 10.1126/science.aax5440.
14. Are We “Brain Washed” during Sleep? [Electronic resource]. – Access mode: <https://www.bu.edu/articles/2019/cerebrospinal-fluid-washing-in-brain-during-sleep/>
15. Deep Sleep Gives Your Brain a Deep Clean [Electronic resource]. – Access mode: <https://www.scientificamerican.com/article/deep-sleep-gives-your-brain-a-deep-clean/>
16. Optimal Brain Surgeon on Artificial Neural Networks in Nonlinear Structural Dynamics / [N. H. Christiansen, J. Hultmann Job, K. Klyver, J. Høgsbrg] // 25th Nordic Seminar on Computational Mechanics (NSCM), 25–26 October 2012 : proceedings. – Lund : Lund University, 2012. – P.319–324.
17. Endisch C. Optimal Brain Surgeon for General Dynamic Neural Networks / C. Endisch, C. Hackl, D. Schröder // Progress in Artificial Intelligence. – 2007. – Vol. 4874. – P. 15–28. DOI: 10.1007/978-3-540-77002-2_2.
18. Oppermann, A. Regularization in Deep Learning – L1, L2, and Dropout [Electronic resource]. Access mode: <https://www.deeplearning-academy.com/p/ai-wiki-regularization>
19. Classic Regularization Techniques in Neural Networks [Electronic resource]. Access mode: <https://medium.com/@ODSC/classic-regularization-techniques-in-neural-networks-68bccee03764>
20. Weight Agnostic Neural Networks [Electronic resource]. Access mode: <https://arxiv.org/pdf/1906.04358.pdf>
21. Weight Agnostic Neural Networks [Electronic resource]. Access mode: <https://weightagnostic.github.io/>
22. Modification and parallelization of genetic algorithm for synthesis of artificial neural networks / [S. D. Leoshchenko, A. O. Oliynyk, S.A. Subbotin et al.] // Radio Electronics,

- Computer Science, Control. – 2019. – № 4. – P. 68–82. DOI: 10.15588/1607-3274-2018-3-12.
23. Implementation of the indicator system in modeling complex technical systems / [S. D. Leoshchenko, S. A. Subbotin, A. O. Oliinyk, O. E. Narivs'kiy] // Radio electronics, computer science, control. – 2021. – № 1. – P. 117–127. DOI: 10.15588/1607-3274-2021-1-12.
24. Sattari M. T. Performance evaluation of artificial neural network approaches in forecasting reservoir inflow / M. T. Sattari, K. Yurekli, M. Pal // Applied Mathematical Modelling. – 2012. – Vol. 36, Issue 6. – P. 2649–2657. DOI: 10.1016/j.apm.2011.09.048.
25. Hassan M. Evaluating the performance of a neural network-based multi-criteria recommender system / M. Hassan, M. Hamada // International Journal of Spatio-Temporal Data Science. – 2019. – Vol. 1 (54) – P. 54–66. DOI: 10.1504/IJSTDS.2019.10018848
26. Jamróz D. The examination of the effect of the criterion for neural network's learning on the effectiveness of the qualitative analysis of multidimensional data / D. Jamróz // Knowledge and Information Systems. – 2020. – Vol. 62. – P. 3263–3289. DOI: 10.1007/s10115-020-01441-8.
27. Субботін С. А. Критерии сравнения распознающих моделей на основе нейронных сетей и анализ их взаимосвязей / С.А. Субботин // Искусственный интеллект. – 2014. – Vol. 1. – P. 142–152.
28. Leoshchenko S. Adaptive Mechanisms for Parallelization of the Genetic Method of Neural Network Synthesis / S. Leoshchenko, A. Oliinyk, S. Subbotin // 10th International Conference on Advanced Computer Information Technologies (ACIT 2020), Deggendorf, 16–18 November : proceedings. – Ternopil: IEEE, 2020. – P. 446–450. DOI: 10.1109/ACIT49673.2020.9208905.
29. Myocardial infarction complications Data Set [Electronic resource]. – Access mode: <https://archive.ics.uci.edu/ml/datasets/Myocardial+infarction+complications>
30. Medical, psychological and physiological applications of MultiNeuron neural simulator / [A. N. Gorban, D. A. Rossiev, E. V. Butakova et al.] // The Second International Symposium on Neuroinformatics and Neurocomputers, Rostov-on-Don, 20–23 September : proceedings. – Rostov-on-Don: IEEE, 1995. – P. 7–14. DOI: 10.1109/ISNINC.1995.480831.
31. Trajectories, bifurcations, and pseudo-time in large clinical datasets: applications to myocardial infarction and diabetes data / [S. E. Golovenkin, J. Bac, A. Chervov et al.] // GigaScience. – 2020. – Vol. 9(11). – P. 1–20. DOI: 10.1093/gigascience/giaa128.

Стаття надійшла до редакції 21.06.2021.
Після доробки 12.07.2021.

УДК 004.896

МЕТОД СТРУКТУРНОЙ ДОНАСТРОЙКИ НЕЙРОСЕТЕВЫХ МОДЕЛЕЙ ДЛЯ ОБЕСПЕЧЕНИЯ ИНТЕРПРЕТАбельНОСТИ

Леошенко С. Д. – аспирант кафедры программных средств Национального университета «Запорожская политехника», Запорожье Украина.

Олейник А. А. – д-р техн. наук, доцент, доцент кафедры программных средств Национального университета «Запорожская политехника», Запорожье Украина.

Субботин С. А. – д-р техн. наук, профессор, заведующий кафедрой программных средств Национального университета «Запорожская политехника», Запорожье Украина.

Гофман Е. А. – старший научный сотрудник научно-исследовательской части Национального университета «Запорожская политехника», Запорожье Украина.

Корниенко А. В. – аспирант кафедры программных средств Национального университета «Запорожская политехника», Запорожье Украина.

АННОТАЦИЯ

Актуальность. Рассмотрена задача структурного изменений предварительно синтезированных моделей на базе искусственных нейронных сетей для обеспечения свойства интерпретабельности при работе с большими объемами данных. Объектом исследования является процесс структурного изменений искусственных нейронных сетей с использованием адаптивных механизмов.

Цель работы заключается в разработке метода структурного изменения нейронных сетей для повышения скорости их работы и уменьшении ресурсоемкости при обработке больших данных.

Метод. Предложен метод структурного донастройки нейронных сетей на основе адаптивных механизмов заимствованных из нейроэволюционных методов синтеза. В начале метод использует систему индикаторов для оценки существующей структуры искусственной нейронной сети. Оценка основывается на структурных особенностях нейромодели. Затем полученные индикаторные оценки сравниваются с критериальными значениями для выбора типа структурного изменений. В качестве вариантов структурного изменения используются варианты мутационных изменений из группы методов нейроэволюционной модификации топологии и весов нейросети. Метод позволяет снизить ресурсоемкость во время работы нейромодели, за счет ускорения обработки больших данных, что расширяет поле практического применения искусственных нейронных сетей.

Результаты. Разработанный метод реализован и исследован на примере использования рекуррентной искусственной сети типа долгая кратковременная память при решении задачи классификации. Использование разработанного метода позволило увеличить скорость работы нейромодели с тестовой выборкой на 25,05 %, в зависимости от используемых вычислительных ресурсов.

Выводы. Проведенные эксперименты подтвердили работоспособность предложенного математического обеспечения и позволяют рекомендовать его для использования на практике при структурной донастройке предварительно синтезированных нейромодели для дальнейшего решения задач диагностирования, прогнозирования, оценивания и распознавания образов с использованием больших данных. Перспективы дальнейших исследований могут заключаться в более тонкой настройке параметров модели.

© Леошенко С. Д., Олейник А. А., Субботин С. А., Гофман Е. А., Корниенко А. В., 2021
DOI 10.15588/1607-3274-2021-3-8

стройке системы индикаторов для определения связей, кодирующих зашумленные данные с целью дополнительного повышения точности работы моделей на основе нейронных сетей.

КЛЮЧЕВЫЕ СЛОВА: интерпретабельность, топология, донастройка структуры, нейроэволюция, нейронные сети.

UDC 004.896

THE METHOD OF STRUCTURAL ADJUSTMENT OF NEURAL NETWORK MODELS TO ENSURE INTERPRETATION

Leoshchenko S. D. – Post-graduate student of the Department of Software Tools, National University “Zaporizhzhia Polytechnic”, Zaporizhzhia, Ukraine.

Oliinyk A. O. – Dr. Sc., Professor, Associate Professor, Associate Professor of the Department of Software Tools, National University “Zaporizhzhia Polytechnic”, Zaporizhzhia, Ukraine.

Subbotin S. A. – Dr. Sc., Professor, Head of the Department of Software Tools, National University “Zaporizhzhia Polytechnic”, Zaporizhzhia, Ukraine.

Gofman Ye. O. – PhD, Senior Researcher of the Research Unit, National University “Zaporizhzhia Polytechnic”, Zaporizhzhia, Ukraine

Korniienko O. V. – Post-graduate student of the Department of Software Tools, National University “Zaporizhzhia Polytechnic”, Zaporizhzhia, Ukraine.

ABSTRACT

Context. The problem of structural modification of pre-synthesized models based on artificial neural networks to ensure the property of interpretation when working with big data is considered. The object of the study is the process of structural modification of artificial neural networks using adaptive mechanisms.

Objective of the work is to develop a method for structural modification of neural networks to increase their speed and reduce resource consumption when processing big data.

Method. A method of structural adjustment of neural networks based on adaptive mechanisms borrowed from neuroevolutionary synthesis methods is proposed. At the beginning, the method uses a system of indicators to evaluate the existing structure of an artificial neural network. The assessment is based on the structural features of neuromodels. Then the obtained indicator estimates are compared with the criteria values for choosing the type of structural changes. Variants of mutational changes from the group of methods of neuroevolutionary modification of the topology and weights of the neural network are used as variants of structural change. The method allows to reduce the resource intensity during the operation of neuromodels, by accelerating the processing of big data, which expands the field of practical application of artificial neural networks.

Results. The developed method is implemented and investigated by the example of using a recurrent artificial network of the long short-term memory type when solving the classification problem. The use of the developed method allowed speed up of the neuromodel with a test sample by 25.05%, depending on the computing resources used.

Conclusions. The conducted experiments confirmed the operability of the proposed mathematical software and allow us to recommend it for use in practice in the structural adjustment of pre-synthesized neuromodels for further solving problems of diagnosis, forecasting, evaluation and pattern recognition using big data. The prospects for further research may consist in a more fine-tuning of the indicator system to determine the connections encoding noisy data in order to further improve the accuracy of models based on neural networks.

KEYWORDS: interpretation, topology, structural adjustment, neuroevolution, neural networks.

REFERENCES

1. Veneri G., Capasso A. Hands-On Industrial Internet of Things: Create a powerful Industrial IoT infrastructure using Industry 4.0. Birmingham, Packt Publishing, 2018, 556 p.
2. Roshak M. Artificial Intelligence for IoT Cookbook: Over 70 recipes for building AI solutions for smart homes, industrial IoT, and smart cities. Birmingham, Packt Publishing, 2021, 260 p.
3. Chantzis F., Stais I., Calderon P., Deirmentzoglou E., Woods B. Practical IoT Hacking: The Definitive Guide to Attacking the Internet of Things. San Francisco, No Starch Press, 2021, 464 p.
4. Nam C. S. Neuroergonomics: Principles and Practice (Cognitive Science and Technology). Berlin, Springer, 2020, 492 p.
5. Caballé S., Demetriadis S. N., Sánchez E. G., Papadopoulos P. M., Weinberger A. Intelligent Systems and Learning Data Analytics in Online Education (Intelligent Data-Centric Systems: Sensor Collected Intelligence). Cambridge, Academic Press, 2021, 424 p.
6. Aggarwal C. C. Neural Networks and Deep Learning: A Textbook, Berlin, Springer, 2018, 520 p.
7. Shikhman V., Müller D. Mathematical Foundations of Big Data Analytics. Berlin, Springer, 2021, 288 p.
8. Deitel P., Deitel H. Intro to Python for Computer Science and Data Science: Learning to Program with AI, Big Data and The Cloud. London, Pearson, 2019, 880 p.
9. D'souza R. N., Huang P.Y., Yeh F.C. Structural Analysis and Optimization of Convolutional Neural Networks with a Small Sample Size, *Scientific Reports*, 2020, No. 10, pp. 1–13. DOI: 10.1038/s41598-020-57866-2.
10. Nowakowski G., Dorogyy Y., Doroga-Ivaniuk O. Neural Network Structure Optimization Algorithm, *Journal of Automation, Mobile Robotics and Intelligent Systems*, 2018, No. 12, pp. 5–13. DOI: 10.14313/JAMRIS_1-2018/1.
11. Iba H. Evolutionary Approach to Machine Learning and Deep Neural Networks, *Neuro-Evolution and Gene Regulatory Networks*. New York, Springer, 2018, 258 p.
12. Izonin I., Tkachenko R., Kryvinska N., Gregus M., Tkachenko P., Vitynskiy P. Committee of SGTN Neural-Like Structures with RBF kernel for Insurance Cost Prediction Task, *2nd Ukraine Conference on Electrical and Computer Engineering (UKRCON), 2–6 July 2019, proceedings*. Lviv, IEEE, 2019, pp. 1037–1040. DOI: 10.1109/UKRCON.2019.8879905.

13. Fultz N. E., Bonmassar G., Setsompop K., Stickgold R. A., Rosen B. R., Polimeni J. R., Lewis L. D. Coupled electrophysiological, hemodynamic, and cerebrospinal fluid oscillations in human sleep, *Science*, 2019, Vol. 366, Issue 6465, pp. 628–631. DOI: 628–631. 10.1126/science.aax5440.
14. Are We “Brain Washed” during Sleep? [Electronic resource], Access mode: <https://www.bu.edu/articles/2019/cerebrospinal-fluid-washing-in-brain-during-sleep/>
15. Deep Sleep Gives Your Brain a Deep Clean [Electronic resource], Access mode: <https://www.scientificamerican.com/article/deep-sleep-gives-your-brain-a-deep-clean/>
16. Christiansen N. H., Hultmann Job J., Klyver K., Høgsbrg J. Optimal Brain Surgeon on Artificial Neural Networks in Nonlinear Structural Dynamics, *25th Nordic Seminar on Computational Mechanics (NSCM), 25–26 October 2012, proceedings*. Lund, Lund University, 2012, pp. 319–324.
17. Endisch C., Hackl C., Schröder D. Optimal Brain Surgeon for General Dynamic Neural Networks, *Progress in Artificial Intelligence*, 2007, Vol. 4874, pp. 15–28. DOI: 10.1007/978-3-540-77002-2_2.
18. Oppermann A. Regularization in Deep Learning – L1, L2, and Dropout [Electronic resource]. Access mode: <https://www.deeplearning-academy.com/p/ai-wiki-regularization>
19. Classic Regularization Techniques in Neural Networks [Electronic resource]. Access mode: <https://medium.com/@ODSC/classic-regularization-techniques-in-neural-networks-68bccee03764>
20. Weight Agnostic Neural Networks [Electronic resource]. Access mode: <https://arxiv.org/pdf/1906.04358.pdf>
21. Weight Agnostic Neural Networks [Electronic resource]. Access mode: <https://weightagnostic.github.io/>
22. Leoshchenko S. D., Oliinyk A. O., Subbotin S. A., Lytvyn V. A., Shkarupilo V. V. Modification and parallelization of genetic algorithm for synthesis of artificial neural networks, *Radio Electronics, Computer Science, Control*, 2019, № 4, P. 68–82. DOI: 10.15588/1607-3274-2018-3-12.
23. Leoshchenko S. D., Oliinyk A. O., Subbotin S. A., Nariv'skiy O. E. Implementation of the indicator system in modeling complex technical systems, *Radio electronics, Computer science, Control*, 2021, No. 1, pp. 117–127. DOI: 10.15588/1607-3274-2021-1-12.
24. Sattari M. T., Yurekli K., Pal M. Performance evaluation of artificial neural network approaches in forecasting reservoir inflow, *Applied Mathematical Modelling*, 2012, Vol. 36, Issue 6, pp. 2649–2657. DOI: 10.1016/j.apm.2011.09.048.
25. Hassan M., Hamada M. Evaluating the performance of a neural network-based multi-criteria recommender system, *International Journal of Spatio-Temporal Data Science*, 2019, Vol. 1 (54), pp. 54–66. DOI: 10.1504/IJSTDS.2019.10018848
26. Jamróz D. The examination of the effect of the criterion for neural network's learning on the effectiveness of the qualitative analysis of multidimensional data, *Knowledge and Information Systems*, 2020, Vol. 62, pp. 3263–3289. DOI: 10.1007/s10115-020-01441-8.
27. Subbotin S.A. Criteria for Comparison of Recognition Models Based on Neural Networks and Analysis of Their Mutual Relations, *Artificial Intelligent*, 2014, Vol. 1, pp. 142–152.
28. Leoshchenko S., Oliinyk A., Subbotin S. Adaptive Mechanisms for Parallelization of the Genetic Method of Neural Network Synthesis. *10th International Conference on Advanced Computer Information Technologies (ACIT 2020), Deggendorf, 16–18 November, proceedings*. Ternopil, IEEE, 2020, pp. 446–450. DOI: 10.1109/ACIT49673.2020.9208905.
29. Myocardial infarction complications Data Set [Electronic resource]. Access mode: <https://archive.ics.uci.edu/ml/datasets/Myocardial+infarction+complications>
30. Gorban A. N., Rossiev D. A., Butakova E. V., Gilev S. E. et al.] Medical, psychological and physiological applications of MultiNeuron neural simulator, *The Second International Symposium on Neuroinformatics and Neurocomputers, Rostov-on-Don, 20–23 September : proceedings*. Rostov-on-Don, IEEE, 1995, pp. 7–14. DOI: 10.1109/ISNINC.1995.480831.
31. Golovenkin S. E., Bac J., Chervov A., Mirkes E. M., Orlova Y. V., Barillot E., Gorban A. N., Zinovyev A. Trajectories, bifurcations, and pseudo-time in large clinical datasets: applications to myocardial infarction and diabetes data, *GigaScience*, 2020, Vol. 9(11), pp. 1–20. DOI: 10.1093/gigascience/giaa128