

ЕВОЛЮЦІЙНИЙ МЕТОД СИНТЕЗУ ІМПУЛЬСНИХ НЕЙРОННИХ МЕРЕЖ З ВИКОРИСТАННЯМ МЕХАНІЗМУ НЕЙРОПАТЕРНІВ

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

Олійник А. О. – д-р техн. наук, професор, професор 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.

Ільяшенко М. Б. – канд. техн. наук, доцент кафедри комп'ютерних систем та мереж Національного університету «Запорізька політехніка», Запоріжжя Україна.

АНОТАЦІЯ

Актуальність. Розглянуто задачу синтезу імпульсних нейронних мереж на основі еволюційного підходу до синтезу штучних нейронних мереж з використанням нейропатерного механізму для побудови діагностичних моделей з високим рівнем точності роботи. Об'єктом дослідження є процес синтезу імпульсних нейронних мереж з використанням еволюційного підходу та нейропатерного механізму.

Мета роботи полягає у розробці методу синтезу імпульсних нейронних мереж на основі еволюційного підходу з використанням нейропатерного механізму для побудови діагностичних моделей з високим рівнем точності роботи.

Метод. Запропоновано метод синтезу імпульсних нейронних мереж на основі еволюційного підходу. На початку генерується популяція імпульсних нейронних мереж, для їх кодування та подальшого розвитку використовується нейропатерний механізм, що полягає в окремому кодуванні нейронів із різними функціями активації, що визначаються попередньо. Так кожен патерн з декількома точками входу може визначати взаємозв'язок між парою точок. В подальшому, це спрощує еволюційний розвиток мереж. Щоб розшифрувати імпульсну нейронну мережу з патерну координати для пари нейронів передаються в мережу, що створює патерн. Вихідний сигнал мережі визначає вагу і затримку з'єднання між двома нейронами в імпульсній нейронній мережі. Після цього можна оцінити кожен нейромодель після еволюційних змін та перевірити критерії зупинки синтезу. Метод дозволяє знизити ресурсоемність під час синтезу мережі, за рахунок абстрагування еволюційних змін патерну мережі від неї самої.

Результати. Розроблений метод реалізовано та досліджено на прикладі синтезу імпульсної нейронної мережі для використання у якості моделі для технічного діагностування. Використання розробленого методу підвищило точність нейромоделі з тестовою вибіркою на 20%, в залежності від використовуваних обчислювальних ресурсів.

Висновки. Проведені експерименти підтвердили працездатність запропонованого математичного забезпечення і дозволяють рекомендувати його для використання на практиці при синтезі імпульсних нейронних мереж у якості основи діагностичних моделей для подальшої автоматизації задач діагностування, прогнозування, оцінювання та розпізнавання образів з використанням великих даних. Перспективи подальших досліджень можуть полягати у використанні нейропатерного механізму для непрямого кодування імпульсних нейронних мереж, що буде забезпечувати, ще більш компактне зберігання даних та пришвидшить процес синтезу.

КЛЮЧОВІ СЛОВА: імпульсна нейронна мережа, топологія, патерн, еволюція, синтез, штучні нейронні мережі, діагностування.

АБРЕВІАТУРИ

CPPN – Compositional Pattern Producing Networks;
MGA – Модифікований генетичний алгоритм;
ReSuMe – Remote supervised learning;
TWEANN – Topology and Weight Evolving Artificial Neural Network;

VP – одиниці вимірювання відстаней між двома коливаннями імпульсу;

ГНМ – глибока нейронна мережа;
ЗПП – зворотне поширення помилки;
ІНМ – імпульсна нейронна мережа;
НП – нейропатерн;
РНМ – рекурентна нейронна мережа;
ШНМ – штучна нейронна мережа.

НОМЕНКЛАТУРА

c – міжнейронні зв'язки ШНМ;
 $Error_{NN}$ – точність роботи ШНМ;

$Error_{task}$ – прийнятна точність;
 $index_{in}$ – індекс першого нейрону в між нейронному зв'язку;
 $index_{out}$ – індекс другого нейрону в між нейронному зв'язку;
 Ind – індивідуум популяції;
 k – кількість міжнейронних зв'язків у ШНМ.
 N_i – множина нейронів на вході мережі;
 N_o – множина нейронів на виході мережі;
 N_h – множина нейронів прихованого шару мережі;
 NN – нейронна мережа;
 $param$ – параметри ШНМ;
 P – популяція індивідуумів;
 ri – випадковий індекс;

struct – структура ШНМ;
Sample – вхідна вибірка даних;
x – пресинаптичний вхід;
X – множина незалежних змінних – ознак;
y^d – бажане значення на виході;
y^{real} – реальне значення на виході.
Y – множина значень залежних змінних.

ВСТУП

З появою та початком активного дослідження результатів роботи IBM TrueNorth увага до ІНМ значно зросла [1–6]. Такі нейронні мережі мають ще більший потенціал у галузі штучного інтелекту ніж ГНМ, РНМ та інші сучасні архітектури ШНМ. Це легко пояснюється легкістю їх влаштування у нейроморфні системи (neuromorphic system). Проте в більшості кейсів виникає складність із синтезом та навчанням таких нейромоделей, адже класичні методи не можуть бути застосовані для таких складних моделей. Ряд робіт пропонує використання CPPN [1–6]. Такий підхід в більшій мірі нагадує інший спосіб синтезу ШНМ, а саме групу еволюційних методів, що разом із мета параметрами мережі еволюційно модифікують її структуру – TWEANN [1–6]. Тож метою цієї роботи є дослідити можливість використання еволюційних методів та окремих їх механізмів під час синтезу ІНМ.

Досить часто ШНМ порівнюють із роботою головного мозку. Проте такі мережі взяли від реальних, живих, організмів тільки саму поверхневу форму і суть. Унаслідок занадто великої відмінності реальних нейронних мереж від ШНМ доводиться винаходити різні сурогатні методи навчання мережі. Природно ніде в природі немає навчання мережі ЗПП, як і немає навчання без вчителя в чистому вигляді [1–6].

ІНМ створювалися з більшою відсилкою на реальну роботу мозку, і використовують спосіб передачі інформації на подоби біологічних нейронів. Так, наприклад, у мозкових нейронах, імпульс генерується в момент, коли поточна сума змін мембранного потенціалу перетинає поріг [1–6]. Швидкість виникнення імпульсів і тимчасова модель пучків імпульсів несуть інформацію про зовнішній подразник і протікають обчисленнях. В основі ІНМ схожий метод генерації імпульсів і передачі інформації: нейрони використовують диференційовані, нелінійні функції активації, застосування яких дозволяє створювати структури товщиною більше одного шару [1–6].

Перша модель ІНМ була запропонована ще в 1952 році Аланом Ходжіном і Ендрю Хакслі [7]. Основна риса такої моделі – це генерація і поширення потенціалів дії в нейронах. Після [7] з біологічними уточненнями і великими обчислювальними витратами були запропоновані різноманітні моделі нейронів: Jolivet, Timothy and Gerstner [8]; Izhikevich [9]; Delorme [10]. Остання дуже популярна, так як вона бере до уваги властивості зовнішнього подразника, акумулюючи

протікання заряду через клітинну мембрану, при перетині певного порогу.

Надалі, завдяки дослідженнями Кохонена, Гроссберга і Андерсона сформувався потужний теоретичний фундамент, за допомогою якого став можливим подальший розвиток ШНМ, а саме проектування і реалізація багатшарових структур [4–6]. Але, навчання, як і раніше, залишається величезною проблемою. Так як функції активації мають похідні, то з'являється простір у використанні градієнтних методів оптимізації для навчання нейронних мереж. З поширенням доступних великих маркованих наборів даних для навчання нейронних мереж, зі збільшенням обчислювальної потужності графічних процесорів і просуnutими методами регуляризації, нейронні мережі стають неймовірно багатшаровими, що дозволяє узагальнювати велику кількість невидимих даних. Багатшаровість-величезна перевага в продуктивності нейронних мереж [1–3].

Добре відомо, що здатність мозку розпізнавати складні візуальні моделі або ідентифікувати оратора в галасливій обстановці це результат декількох послідовних етапів обробки і безлічі механізмів навчання, які також вбудовані в ІНМ з глибоким навчанням [7–10]. У порівнянні з ГНМ, навчання ІНМ відбувається на самих ранніх етапах розвитку. Важливою особливістю такого типу систем є нейронна архітектура. Вона набагато краще підходить для обробки просторово-часових даних, особливо в онлайн режимі. Представлення даних у часі і просторі, яким володіють ІНМ, дозволяє таким нейромережам виконувати обчислення на рівні з людським мозком, а також розуміти діяльність мозку в просторово-часовій структурі. Дуже важливо в найближчі роки зрозуміти, як навчити такі нейромережі виконувати різні завдання [1–6].

Якщо подивитися на ІНМ з інженерної точки зору, то цей тип нейромереж має ряд переваг в апаратній реалізації над звичайними ШНМ. Пучки імпульсів в ІНМ розкидані в часі, кожен з них містить величезну кількість інформації, що дозволяє значно знизити енергоспоживання. Таким чином, можна створити апаратну платформу із помірними показниками ресурсоемності, що підлаштовує свою роботу під імпульсну активність. Приклад ІНМ наведено на рис. 1.

Проте, більшість методів навчання ІНМ є все тими ж модифікаціями методу ЗПП з певними адаптаціями до більш складної архітектури ІНМ [11]. Більш того, такі методи не в якому разі не дотичні до етапу синтезу саме топології мережі. Саме тому актуальною є задача розроблення нових методів на основі еволюційного підходу для повноцінного синтезу ІНМ.

Об'єкт дослідження – процес синтезу ІНМ.

Існуючі методи навчання ІНМ забезпечують виконання виключно етапу параметричного синтезу нейромоделі без виконання попереднього структурного синтезу. Це призводить до невизначеності структури ІНМ та проблеми із подальшою практичною імплементацією.




Рисунок 1 – Приклад імплементації ІНМ

Предмет дослідження – метод еволюційного синтезу ІНМ із використанням нейронного механізму.

На сьогоднішній день існує група методів, які застосовують ЗПП до ІНМ. Але такі методи не можуть використовувати традиційні механізми методу ЗПП і змінювати оновлення градієнта або самі ІНМ, і більш того накладають архітектурні обмеження на отримані ІНМ, наприклад, вимагаючи архітектури ІНМ з прямим зв'язком. Отже, існує безліч топологій ІНМ, які не можуть бути оптимізовані за допомогою цих методів. Тому, у роботі запропоновано підхід, що базується на використанні еволюційного підходу, що забезпечує і структурний, і параметричний синтез нейромоделі.

Мета роботи – розробка методу еволюційного синтезу ІНС з використанням нейронного механізму для побудови діагностичних моделей.

1 ПОСТАНОВКА ПРОБЛЕМИ

Нехай маємо вибірку даних $Sample = \langle X, Y \rangle$, яка складається з множини незалежних змінних $X = \{x_1, x_2, \dots, x_n\}$, що є інформаційними ознаками ознак та множини значень залежних змінних $Y = \{y_1, y_2, \dots, y_m\}$, які характеризуються ознаками, тоді n та m – кількість незалежних та залежних змінних (ознак та екземплярів). вхідних ознак, що характеризують екземпляри вибірки.

Тоді використовуючи еволюційний підхід для синтезу ШНМ, ініціалізуємо популяцію ІНМ $P = \{NN_1, NN_2, NN_3, \dots, NN_l\}$, де кожна особина ІНМ буде характеризуватися виключно множиною нейронів $NN_{ri} = Ind_{ri} = \{N_i, N_h, N_o\}$.

Тоді задача синтезу ІНМ буде полягати в тому, щоб через внесення еволюційних змін до структури особин популяції розподілити міжнейронні зв'язки, що будуть відображати взаємозв'язки в даних $struct_{Ind_{ri}} = struct_{NN_{ri}} = \{N_i, N_h, N_o, c\}$, такі зв'язки будуть характеризуватися індексами входу/виходу та ваговим коефіцієнтом

$c = \{c, index_{in}, index_{out}, w\}$, $w = \{w_k\}$. Отримане рішення має забезпечувати прийнятну точність роботи $Error_{NN} \leq Error_{task}$.

2 ОГЛЯД ЛІТЕРАТУРИ

Варто відзначити, що натхненні біологічним прикладом ІНМ, в принципі, набагато краще і швидше розпізнають образи, ніж звичайні ШНМ [11]. Більш того, ІНМ дозволяють використовувати методи навчання, що залежать від часу виникнення імпульсів між парами безпосередньо з'єднаних нейронів, в яких інформація для зміни ваги ребер доступна локально. Цей метод навчання дуже нагадує те, що відбувається в багатьох частинах мозку.

Виникаючі пучки імпульсів представляють у вигляді недиференційованих сум дельта-функцій. Відповідно, складно застосовувати методи оптимізації, засновані на похідних, для навчання ІНМ, хоч і останнім часом активно йде дослідження різних типів наближених похідних. Незважаючи на те, що в теорії імпульсні нейронні мережі мають еквівалентну за Тьюрингом обчислювальну потужність [12], все ще проблематично навчати ІНМ, особливо ті, що мають багатопшарову архітектуру. У багатьох існуючих імпульсних нейронних мережах, навчати можна лише один шар. Якщо вийде забезпечити імпульсні системи багатопшаровим навчанням, то продуктивність в різного роду завданнях виросте в десятки разів.

Архітектура імпульсних нейронних мереж складається з імпульсних нейронів і взаємопов'язаних синапсів [7–9]. Пучки імпульсів в нейронних мережах імпульсних нейронів поширюються через синаптичні зв'язки. Синапс може бути як збудливим, коли мембранний потенціал нейрона зростає після отримання сигналу, так і уповільнює. Величина ваги ребер може змінюватися в результаті навчання. Глибоке навчання багатопшарових ІНМ – це справжня головоломка, так як недиференційованість пучків імпульсів не дозволяє використовувати популярні методи, такі як метод зворотного поширення [13–14].

Як зазначалося, навчання всіляких штучних нейронних мереж відбувається за рахунок коригування

скалярних синаптичних ваг (рис. 2). В ІНМ можна використовувати методи навчання наближені до тих, які використовує мозок. Вчені визначили безліч варіантів цього методу навчання, але всі вони потрапляють під загальний термін дендритної пластичності [15]. Ключовою особливістю дендритної пластичності є те, що вага ребра, що з'єднує пре- і постсинаптичні нейрони, регулюється з часом їх імпульсу в інтервалі приблизно в десятки мілісекунд за довжиною.




Рисунок 2 – Використання методу ЗПП

Метод SpikeProp. Це перший метод навчання ІНМ шляхом зворотного поширення помилок [16]. Функція вартості враховує період коливання і, завдяки цьому, цей метод може класифікувати нелінійно розділені дані для завдання XOR з тимчасовим кодуванням з використанням 3-рівневої архітектури. Головним рішенням на етапі розробки методу був вибір моделі нейрона Герсгнера [175]. Використовуючи цю модель, питання взяття похідних на виході коливання обтікався, так як необхідний результат безпосередньо моделювався як безперервне значення [16, 17]. Одним з обмежень цього способу є те, що кожна вихідна одиниця була змушена генерувати рівно одне коливання. Крім того, значення безперервних змінних, таких як в задачах XOR, повинні були бути закодовані як затримки між коливаннями, які можуть бути досить довгими [16, 17].

Метод ReSuMe. Дана модель навчання складається з одного нейрона, що коливається, на вхід якого приймаються коливання від безлічі інших коливних пресинаптичних нейронів [18]. Метою є навчити синапс викликати постсинаптичний нейрон для генерування хвиль коливань з бажаним періодом коливання. ReSuMe адаптував Дельта-правило, що використовується для неімпульсних лінеаризованих одиниць, до ІНМ. У Дельта-правилі ваги змінюються пропорційно [18]:

$$\Delta\omega = (y^d - y^{real})x = y^d x - y^{real} x. \quad (1)$$

Переформулювавши рівняння (1) можна отримати суму STDP і anti-STDP:

$$\Delta\omega = \Delta\omega^{STDP}(S^{in}, S^d) + \Delta\omega^{aSTDP}(S^{in}, S^{real}), \quad (2)$$

Вище $\Delta\omega^{STDP}$ – це функція кореляції пресинаптичних і бажаних періодів коливань, тоді як $\Delta\omega^{aSTDP}$ – залежить від пресинаптичних і реальних періодів коливань. Так як цей метод використовує кореляцію між безліччю пресинаптичних нейронів і вагається нейроном, то ніякої фізичної зв'язку між ними немає. Ось чому цей метод називають віддаленим.

Метод Chronotron. Цей метод був розроблений на основі методу Tempotron [19], який міг навчати окремі нейрони розпізнавати кодування за точним часом приходу коливання.

Цей метод був розроблений на основі методу Tempotron [19], який міг навчати окремі нейрони розпізнавати кодування за точним часом приходу коливання. Обмеженням методу Tempotron була можливість видавати 0 або 1 на виході протягом обраного інтервалу часу. Через це у вихідні дані неможливо було закодувати інформацію про час приходу коливання. На створення Chronotron вплинув успіх SpikeProp і його наступників. Ідеєю Chronotron було використовувати для навчання більш складні одиниці вимірювання відстаней – VP [20] між двома коливаннями. Вони адаптували відстань VP так, щоб воно було кусочно-диференційованим і підходило в якості функції вартості для виконання градієнтного спуску по відношенню до ваг.

Серед існуючих методів виділяють декілька основних недоліків. По-перше, для кожного каналу потрібна окрема схема швидкого збігу. Тобто є ризик множення похідних на кожному каналі, що в подальшому може накласти великі обчислювальні потреби.

По-друге, стає досить складно отримати велику кількість каналів через спотворень імпульсів, які виникають при підключенні ланцюгів збігу до коаксіальних кабелів.

Але ключовою проблемою завжди залишається питання топології (структури такої мережі). Існує безліч підходів, які застосовують зворотне поширення до ІНМ. Але такі методи не можуть використовувати традиційне зворотне поширення і змінювати оновлення градієнта або самі ІНМ, щоб подолати цю складність. Ці типи методів часто накладають архітектурні обмеження на отримані ІНМ, наприклад, вимагаючи архітектури ІНМ з прямим зв'язком. Отже, існує безліч топологій ІНМ з бажаними властивостями, такими як повторюваність, які не можуть бути оптимізовані за допомогою цих методів.

Саме тому є актуальною задачею розробка еволюційних методів для повноцінного синтезу ІНМ-моделі. При імплементації методів еволюційного підходу оцінювання популяції ІНМ дозволить в подальшому використовувати процеси стохастичної варіації і відбору для створення наступної популяції або контролювати ці процеси. Протягом послідовних ітерацій мутацій та відбору мереж-індивідуумів із зростаючою придатністю, яку можна широко визначити як точність у задачі класифікації або максимальної винагороди з навколишнього середовища, нові рішення бу-

дуть якісно відрізнитися від попередніх. Однією з істотних переваг еволюційних підходів є їх гнучкість. Стосовно ІНМ еволюційна оптимізація потенційно може впливати на будь-яку топологію мережі, а також оптимізувати будь-який мережевий параметр.

3 МАТЕРІАЛИ ТА МЕТОДИ

Загалом метод, що запропонований в роботі схожий на MGA для синтезу звичайних ШНМ [21, 22]. Так, на початку слід зазначити, що для виконання синтезу використовується пряме кодування структури індивідуумів, кожен з яких є окремою нейронною мережею, проте основою такого кодування є між нейронні зв'язки. За рахунок цього можливо більш детально відстежувати походження кожного параметра (вузла або з'єднання) в геномі. На наступних етапах методу це в значній мірі спрощує процеси схрещування та мутації, дозволяючи вибудовувати та змінювати генетичну інформацію про особини і мінятися місцями під час схрещування [21, 22].

Основною інновацією є використання певних шаблонних механізмів, а саме НП на основі технології CPPN [23]. Цей механізм забезпечує абстрагування процесів природної еволюції [23]. НП будуть складатися із нейронів з різними функціями активації, включаючи періодичні функції, такі як синусоїдальні та симетричні функції, такі як абсолютне значення. Основна ідея заснована на тому, що НП на базі CPPN із декількома точками входу може визначати взаємозв'язок між парою точок. Фіксований набір нейронів, вводиться у вигляді певного субстрат до НП, що надалі спрощує нейросинтез з використанням MGA [21, 22].

Загалом на початку еволюції отримуємо популяцію із NP, які визначають шаблони підключення результуючих ІНМ. Кожний NP визначається закодованою генетичною інформацією із визначенням його внутрішніх ваг і функціями активації. Проте важливо зазначити, що кожний окремий нейрон в НП може мати будь-яку функцію активації з певного набору (\sin , \tanh , gauss , relu , identity). Щоб розшифрувати ІНМ із НП координати для пари нейронів передаються в мережу, що створює НП (рис. 4). Вихідний сигнал мережі визначає вагу і затримку з'єднання між двома нейронами в пікіруючій нейронній мережі. Цей процес повторюється для кожної пари нейронів, щоб побудувати повну мережу.

Після підготовки популяції можливо виконувати подальший синтез. Основні кроки синтезу та дешифрування ІНМ з НП наведено на рис. 3 [21, 22].

Проте слід зазначити декілька нюансів цього синтезу:

- положення нейронів ІНМ, у вигляді НП заздалегідь фіксуються на час еволюційного пошуку для кожної особини. Тобто будь-яка мутація та модифікація можлива тільки у вигляді нової особини;
- кожне рішення дешифрується і оцінюється для виконання заданого завдання (класифікація або управління). Отже, придатність рішення визначається продуктивністю згенерованої ІНМ для зазначеного завдання;
- видоутворення використовується для захисту інновацій в нових рішеннях та може припинитися за умови їх відсутності.

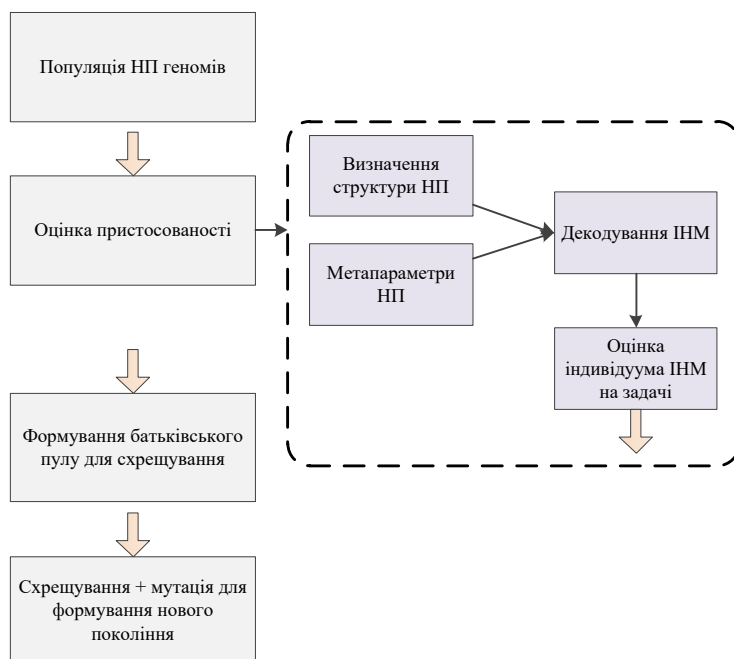


Рисунок 3 – Загальний процес синтезу ІНМ




Рисунок 4 – Приклад декодування ІНМ з НН

4 ЕКСПЕРИМЕНТИ

Для дослідження результатів роботи методу було обрано задачу на основі набору даних HIGGS Data Set з відкритого джерела UCI Machine Learning Repository [24]. Для навчання використовувалася 75% (частина) вибірки, для тестування проводилося на 25% вибірки. Загальну ж інформацію про вибірку наведено у табл. 1.

Таблиця 1 – Загальна характеристика вибірки даних HIGGS Data Set

Критерій	Характеристика
Характеристики вибірки даних:	Багатоваріантна
Атрибутивні характеристики:	Real
Кількість примірників:	11000000
Кількість атрибутів	28

Результативність ІНМ-моделей буде порівнюватися із нейромоделями на базі РНМ (рис. 5 а) та ГНМ (рис. 5 б) [25].

РНМ це один з типів ШНМ і використовується в областях застосування природного опрацювання мови та розпізнавання мовлення [25]. Модель РНМ розроблена для розпізнавання послідовних характеристик даних і надалі з використанням шаблонів для прогнозування майбутнього сценарію. ГНМ це нейронна мережа з певним рівнем складності, нейронна мережа з більш ніж двома шарами. ГНМ використовують складне математичне моделювання для обробки даних складними способами [25].




Рисунок 5 – Топології ШНМ для порівняння результатів під час експериментального дослідження

5 РЕЗУЛЬТАТИ

У таблиці 2 представлено результати роботи методів синтезу із різними топологіями нейромереж.

Таблиця 2 – Порівняння результатів роботи

Метод синтезу	Час синтезу, с	Помилка на навчальній вибірці	Помилка на тестовій вибірці
MGA ІНМ	20200,32	0,016	0,051
MGA РНМ	14672,88	0,028	0,063
MGA ГНМ	7625	0,022	0,052

6 ОБГОВОРЕННЯ

Переглядаючи тестові результати можна прийти до висновків, що пропозиція використовувати еволюційні методи для синтезу ІНМ демонструє хороші результати для її подальшого розгортання та використання. Адже, для мереж цього класу завжди є актуальним питання складної та іноді не до кінця чіткої структури. Використання ж еволюційних підходів із кодуванням та декодуванням НП значно полегшує цю задачу, адже в цьому випадку структурний синтез зводиться до відомих підходів із еволюційного синтезу із використанням TWEANN. Параметричний же синтез представляє собою тонке налаштування на виключно визначених етапах без необхідності ітераційно знов і знов обраховувати fitness functions або її похідні.

З іншого ж боку можна зробити висновок, що практичне використання нейромереж класу ІНМ поки що є виключно перспективним, адже отримані результати точності роботи не можуть в повній мірі продемонструвати доцільність значних часових витрат. Так величини похибок в обох випадках (навчання та тестування) не відрізняються значущістю, яка б могла покрити часові витрати на синтез таких мереж та їх подальші обрахунки. Адже варто зазначити, що за умови відсутності спеціалізованого устаткування для емуляції роботи ІНМ виконання цього процесу на звичайній робочій станції також супроводжується часовими накладками.

Також варто окремо проаналізувати роботи із складними топологіями класичних ШНМ. Так, відмінності у часі синтезу пояснюються більш простим обрахунком та коригуванням рекурентних зв'язків на відмінно від обрахунку вузлів та ваг міжнейронних зв'язків у множині прихованих шарів. А аналіз точності роботи синтезованих рішень на навчальних та тестових даних демонструє, що різниця в точності не є критичною та прийнятна в рамках задачі. Саме тому можна говорити про конкретну вказівку, про використання тієї чи іншої топології ШНМ в залежності, який з ресурсів є більш важливим: час синтезу та роботи нейромоделі або ж її точність.

ВИСНОВКИ

Вирішено актуальну науково-прикладну проблему розроблення методу синтезу ІНМ на основі еволюційного підходу з використанням нейропатерного механізму.

Наукова новизна полягає в тому що розроблено метод еволюційного синтезу складних топологій ШНМ, а саме ІНМ з використанням нейропатернів. У запропонованому методі використовуються техніка кодування особин, кожна з яких окрема ІНМ, заснована на використанні спеціальних НП, що абстрагують еволюційні процеси від самих складних структур ІНМ, оптимізуючи ресурси на етапах кодування та декодування.

Практична цінність полягає в тому, що розв'язано практичні завдання синтезу ІНМ, що можуть використовуватися для діагностування, прогнозування, оцінювання та розпізнавання образів, забезпечуючи високу точність. Результати експериментів показали, що запропонований метод може використовуватися на практиці та дозволяє синтезувати точніші ІНМ для їх подальшого використання у якості моделей для діагностування, прогнозування, оцінювання та моделювання.

Майбутні напрями дослідження та розробки полягають запровадженні та використанні методів непрямого кодування НП та загалом особин ШНМ під час синтезу. Такі підходи можуть допомогти більш детально вивчити множину варіантів взаємозв'язків між унікальними характеристиками ІНМ. Наприклад, різні стратегії кодування вхідних даних можуть спричинити варіативність конфігурації нейронів для НП.

ПОДЯКИ

Робота була проведена за підтримки держбюджетних науково-дослідницьких проектів державного бюджету Національного університету «Запорізька політехніка» «Інтелектуальні методи та засоби діагностування та прогнозування стану складних об'єктів» (номер державної реєстрації 0122U000972) та «Розроблення методів та засобів для аналізу та прогнозування динамічної поведінки нелінійних об'єктів» номер державної реєстрації 0121U107499).

ЛІТЕРАТУРА / LITERATURA

1. Ping D. The Machine Learning Solutions Architect Handbook: Create machine learning platforms to run solutions in an enterprise setting / D. Ping. – Birmingham : Packt Publishing, 2022. – 442 p.
2. Burkov A. Machine Learning Engineering / A. Burkov. – Quebec City: True Positive Inc., 2020. – 310 p.
3. Alkhalifa S. Machine Learning in Biotechnology and Life Sciences: Build machine learning models using Python and deploy them on the cloud / S. Alkhalifa. – Birmingham : Packt Publishing, 2022. – 408 p.
4. Aggarwal C. C. Neural Networks and Deep Learning: A Textbook / C. C. Aggarwal. – Berlin : Springer, 2018. – 520 p.
5. Hiesinger P. R. The Self-Assembling Brain: How Neural Networks Grow Smarter / P. R. Hiesinger. – Princeton : Princeton University Press, 2021. – 384 p.
6. Graupe D. Principles of Artificial Neural Networks: Basic Designs to Deep Learning (4th Edition) (Advanced Circuits and Systems) / D. Graupe. – Singapore: WSPC, 2019. – 438 p.
7. Hodgkin A. A quantitative description of membrane current and its application to conduction and excitation in nerve /

- A. Hodgkin, A. Huxley // *J. Physiol.* – 1952. – Vol. 117(4). – P. 500–544. DOI: 10.1113/jphysiol.1952.sp004764
8. The Spike Response Model: A Framework to Predict Neuronal Spike Trains / [R. Jolivet, J. Timothy, W. Gerstner] // International conference on Artificial neural networks and neural information processing, ICANN/ICONIP'03, Istanbul, 26–29 June 2003 : proceedings. – Istanbul: ACM Digital Library, 2003. – P. 846–853. DOI: 10.1007/3-540-44989-2_101
 9. Izhikevich E. Simple model of spiking neurons / E. Izhikevich // *Transactions of neural networks.* – 2003. – Vol. 14. – P. 1569–1572. DOI: 10.1109/TNN.2003.820440
 10. SpikeNET: A simulator for modeling large networks of integrate and fire neurons / [A. Delorme, J. Gautrais, R. van Rullen, S. Thorpe] // *Neurocomputing.* – 1999. – Vol. 26(7). – P. 989–996. DOI: 10.1016/S0925-2312(99)00095-8
 11. Pfeiffer M. Deep learning with spiking neurons: Opportunities and challenges / M. Pfeiffer, T. Pfeil // *Frontiers in Neuroscience.* – 2018. – Vol. 12: 774. – P. 32–50. DOI: 10.3389/fnins.2018.00774
 12. Maass W. Lower bounds for the computational power of networks of spiking neurons / W. Maass // *Neural Computation.* – 1996. – Vol. 8. – P. 1–40.
 13. Development of programmable home security using GSM system for early prevention / [J. A. J. Alsayaydeh, A. Aziz, A. I. A. Rahman et al.] // *ARPN Journal of Engineering and Applied Sciences.* – 2021. – Vol. 16(1). – P. 88–97.
 14. Development of vehicle ignition using fingerprint / [J.A.J. Alsayaydeh, W. A. Indra, W. A. Y. Khang et al.] // *ARPN Journal of Engineering and Applied Sciences.* – 2019. – Vol. 14(23). – P. 4045–4053.
 15. A spike-timing-dependent plasticity rule for dendritic spines / [S. Tazerart, D. E. Mitchell, S. Miranda-Rottmann, R. Araya] // *Nature Communications.* – 2020. – Vol. 11. – P. 12–23. DOI: 10.1038/s41467-020-17861-7
 16. Bohte S. M. Error-backpropagation in temporally encoded networks of spiking neurons / S. M. Bohte // *Artificial Neural Network and Machine Learning, ICANN 2011, Espoo, 11–14 June 2011 : proceedings.* – Espoo: ACM Digital Library, 2011. – P. 60–68.
 17. Gerstner W. Spiking neuron models: Single neurons, populations, plasticity / W. Gerstner, W. M. Kistler. – Cambridge : Cambridge University Press, 2002. – 496 p.
 18. Ponulak F. Supervised learning in spiking neural networks with ReSuMe: Sequence learning, classification, and spike shifting / F. Ponulak, A. Kasinski // *Neural Computation.* – 2009. – Vol. 22. – P. 467–510. DOI: 10.1162/neco.2009.11-08-901
 19. Gütig R. The tempotron: A neuron that learns spike timing-based decisions / R. Gütig, H. Sompolinsky // *Nature Neuroscience.* – 2006. – Vol. 9. – P. 420–428. DOI: 10.1038/nn1643
 20. Serre T. Hierarchical models of the visual system, *Encyclopedia of Computation Neuroscience* / T. Serre. – New York : Springer, 2014. – 15 p. DOI: 10.1007/978-1-4614-7320-6_345-1
 21. Synthesis of artificial neural networks using a modified genetic algorithm / [S. Leoshchenko, A. Oliinyk, S. Subbotin et al.] // 1st International Workshop on Informatics & Data-Driven Medicine (IDDM 2018), Lviv, 28–30 October, 2018 : proceedings. – Lviv : CEUR WS, 2018. – P. 1–13.
 22. Modification and parallelization of genetic algorithm for synthesis of artificial neural networks / [S. D. Leoshchenko, A. O. Oliinyk, S. A. Subbotin et al.] // *Radio Electronics, Computer Science, Control.* – 2019. – № 4. – P. 68–82. DOI: 10.15588/1607-3274-2019-4-7
 23. Elbrecht D. Neuroevolution of Spiking Neural Networks Using Compositional Pattern Producing Networks / D. Elbrecht, C. Schuman // *International Conference on Neuro-morphic Systems 2020, ICONS 2020, Knoxville, 27–29 July 2020 : proceedings.* – Knoxville : ACM Digital Library, 2020. – P. 1–5. DOI: 10.1145/3407197.3407198
 24. HIGGS Data Set [Electronic resource]. – Access mode: <https://archive.ics.uci.edu/ml/datasets/HIGGS>
 25. A Using modern architectures of recurrent neural networks for technical diagnosis of complex systems / [S. Leoshchenko, A. Oliinyk, S. Subbotin, T. Zaiko] // *International Scientific-Practical Conference Problems of Infocommunications. Science and Technology (PIC S&T), Kharkiv, 9–12 October 2018 : proceedings.* – Kharkiv : IEEE, 2018. – P. 411–416. DOI: 10.1109/INFOCOMMST.2018.8632015

Стаття надійшла до редакції 20.06.2022.
Після доробки 24.08.2022.

UDC 004.896

EVOLUTIONARY METHOD FOR SYNTHESIS SPIKING NEURAL NETWORKS USING THE NEUROPATHERN MECHANISM

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

Oliinyk A. O. – Dr. Sc., Professor, 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.

Ilyashenko M. B. – PhD, Associate Professor, Associate Professor of the Department of Computer Systems and networks, National University “Zaporizhzhia Polytechnic”, Zaporizhzhia, Ukraine.

ABSTRACT

Context. The problem of synthesizing pulsed neural networks based on an evolutionary approach to the synthesis of artificial neural networks using a neuropathic mechanism for constructing diagnostic models with a high level of accuracy is considered. The object of research is the process of synthesis of pulsed neural networks using an evolutionary approach and a neuropathic mechanism.

Objective of the work is to develop a method for synthesizing pulsed neural networks based on an evolutionary approach using a neuropathic mechanism to build diagnostic models with a high level of accuracy of work.

© Леошенко С. Д., Олійник А. О., Субботін С. О., Гофман Є. О., Ільяшенко М. Б., 2022
DOI 10.15588/1607-3274-2022-3-8

Method. A method for synthesizing pulsed neural networks based on an evolutionary approach is proposed. At the beginning, a population of pulsed neural networks is generated, and a neuropathic mechanism is used for their encoding and further development, which consists in separate encoding of neurons with different activation functions that are determined beforehand. So each pattern with multiple entry points can define the relationship between a pair of points. In the future, this simplifies the evolutionary development of networks. To decipher a pulsed neural network from a pattern, the coordinates for a pair of neurons are passed to the network that creates the pattern. The network output determines the weight and delay of the connection between two neurons in a pulsed neural network. After that, you can evaluate each neuromodel after evolutionary changes and check the criteria for stopping synthesis. This method allows you to reduce the resource intensity during network synthesis by abstracting the evolutionary changes of the network pattern from itself.

Results. The developed method is implemented and investigated on the example of the synthesis of a pulsed neural network for use as a model for technical diagnostics. Using the developed method to increase the accuracy of the neuromodel with a test sample by 20%, 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 synthesis of pulsed neural networks as the basis of diagnostic models for further automation of tasks of diagnostics, forecasting, evaluation and pattern recognition using big data. Prospects for further research may lie in the use of a neuropathic mechanism for indirect encoding of pulsed neural networks, which will provide even more compact data storage and speed up the synthesis process.

KEYWORDS: spiking neural network, topology, pattern, evolution, synthesis, artificial neural networks, diagnostics.

REFERENCES

1. Ping D. The Machine Learning Solutions Architect Handbook: Create machine learning platforms to run solutions in an enterprise setting. Birmingham, Packt Publishing, 2022, 442 p.
2. Burkov A. Machine Learning Engineering. Quebec City, True Positive Inc., 2020, 310 p.
3. Alkhalifa S. Machine Learning in Biotechnology and Life Sciences: Build machine learning models using Python and deploy them on the cloud. Birmingham, Packt Publishing, 2022, 408 p.
4. Aggarwal C. C. Neural Networks and Deep Learning: A Textbook. Berlin, Springer, 2018, 520 p.
5. Hiesinger P. R. The Self-Assembling Brain: How Neural Networks Grow Smarter. Princeton, Princeton University Press, 2021, 384 p.
6. Graupe D. Principles of Artificial Neural Networks: Basic Designs to Deep Learning (4th Edition) (Advanced Circuits and Systems). Singapore, WSPC, 2019, 438 p.
7. Hodgkin A., Huxley A. A quantitative description of membrane current and its application to conduction and excitation in nerve, *J. Physiol.*, 1952, Vol. 117(4), pp. 500–544. DOI: 10.1113/jphysiol.1952.sp004764
8. Jolivet R., Timothy J., Gerstner W. The Spike Response Model: A Framework to Predict Neuronal Spike Trains, *International conference on Artificial neural networks and neural information processing, ICANN/ICONIP'03, Istanbul, 26–29 June 2003, proceedings*. Istanbul. ACM Digital Library, 2003, pp. 846–853. DOI: 10.1007/3-540-44989-2_101
9. Izhikevich E. Simple model of spiking neurons, *Transactions of neural networks*, 2003, Vol. 14, pp. 1569–1572. DOI: 10.1109/TNN.2003.820440
10. Delorme A., Gautrais J., van Rullen R., Thorpe S. SpikeNET: A simulator for modeling large networks of integrate and fire neurons, *Neurocomputing*, 1999, Vol. 26(7), pp. 989–996. DOI: 10.1016/S0925-2312(99)00095-8
11. Pfeiffer M., Pfeil T. Deep learning with spiking neurons: Opportunities and challenges, *Frontiers in Neuroscience*, 2018, Vol. 12: 774, pp. 32–50. DOI: 10.3389/fnins.2018.00774
12. Maass W. Lower bounds for the computational power of networks of spiking neurons, *Neural Computation*, 1996, Vol. 8, pp. 1–40.
13. Alsayaydeh J.A.J., Aziz A., Rahman A.I.A., Salim S.N.S., Zainon M., Baharudin Z.A., Abbasi M.I., Khang A.W.Y. Development of programmable home security using GSM system for early prevention, *ARN Journal of Engineering and Applied Sciences*, 2021, Vol. 16(1), pp. 88–97.
14. Alsayaydeh J.A.J., Indra W.A., Khang W.A.Y., Shkarupylo V., Jkatisan D.A.P.P. Development of vehicle ignition using fingerprint, *ARN Journal of Engineering and Applied Sciences*, 2019, Vol. 14(23), pp. 4045–4053.
15. Tazerart S., Mitchell D. E., Miranda-Rottmann S., Araya R. A spike-timing-dependent plasticity rule for dendritic spines, *Nature Communications*, 2020, Vol. 11, pp. 12–23. DOI: 10.1038/s41467-020-17861-7
16. Bohte S.M. Error-backpropagation in temporally encoded networks of spiking neurons, *Artificial Neural Network and Machine Learning, ICANN 2011, Espoo, 11–14 June 2011, proceedings*. Espoo, ACM Digital Library, 2011, pp. 60–68.
17. Gerstner W., Kistler W. M. Spiking neuron models: Single neurons, populations, plasticity. Cambridge, Cambridge University Press, 2002, 496 p.
18. Ponulak F., Kasinski A. Supervised learning in spiking neural networks with ReSuMe: Sequence learning, classification, and spike shifting, *Neural Computation*, 2009, Vol. 22, pp. 467–510. DOI: 10.1162/neco.2009.11-08-901
19. Gütig R., Sompolinsky H. The tempotron: A neuron that learns spike timing-based decisions, *Nature Neuroscience*, 2006, Vol. 9, pp. 420–428. DOI: 10.1038/nn1643
20. Serre T. Hierarchical models of the visual system, *Encyclopedia of Computation Neuroscience*. New York, Springer, 2014, 15 p. DOI: 10.1007/978-1-4614-7320-6_345-1
21. Leoshchenko S., Oliinyk A., Subbotin S., Gorobii N., Zaiko T. Synthesis of artificial neural networks using a modified genetic algorithm, *1st International Workshop on Informatics & Data-Driven Medicine (IDDM 2018), Lviv, 28–30 October, 2018, proceedings*. Lviv, CEUR WS, 2018, pp. 1–13.
22. Leoshchenko S. D., Oliinyk A. O., Subbotin S. A., Lytvyn V. A., Shkarupylo V. V. Modification and parallelization of genetic algorithm for synthesis of artificial neural networks, *Radio Electronics, Computer Science, Control*, 2019, No. 4, P. 68–82. DOI: 10.15588/1607-3274-2019-4-7
23. Elbrecht D., Schuman C. Neuroevolution of Spiking Neural Networks Using Compositional Pattern Producing Networks, *International Conference on Neuromorphic Systems 2020, ICONS 2020, Knoxville, 27–29 July 2020, proceedings*. Knoxville, ACM Digital Library, 2020, pp. 1–5. DOI: 10.1145/3407197.3407198
24. HIGGS Data Set [Electronic resource]. Access mode: <https://archive.ics.uci.edu/ml/datasets/HIGGS>
25. Leoshchenko S., Oliinyk A., Subbotin S., Zaiko T. A Using modern architectures of recurrent neural networks for technical diagnosis of complex systems, *International Scientific-Practical Conference Problems of Infocommunications. Science and Technology (PIC S&T), Kharkiv, 9–12 October 2018, proceedings*. Kharkiv, IEEE, 2018, pp. 411–416. DOI: 10.1109/INFOCOMMST.2018.8632015